



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE CIÊNCIAS AGRÁRIAS
DEPARTAMENTO DE ENGENHARIA AGRÍCOLA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

MARCELO QUEIROZ AMORIM

APLICAÇÃO DE TÉCNICAS DE AGRUPAMENTO E REDE NEURAL ARTIFICIAL
EM ACIDENTES COM MÁQUINAS AGRÍCOLAS

FORTALEZA

2022

MARCELO QUEIROZ AMORIM

APLICAÇÃO DE TÉCNICAS DE AGRUPAMENTO E REDE NEURAL ARTIFICIAL EM
ACIDENTES COM MÁQUINAS AGRÍCOLAS

Tese apresentada ao Programa de Pós-Graduação em Engenharia Agrícola da Universidade Federal do Ceará, como requisito para obtenção do título de Doutor em Engenharia Agrícola. Área de concentração: Engenharia de Sistemas Agrícolas.

Orientador: Prof. Dr. Leonardo de Almeida Monteiro.

FORTALEZA

2022

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

Amorim, Marcelo Queiroz.

Aplicação de técnicas de agrupamento e rede neural artificial em acidentes com máquinas agrícolas /
Marcelo Queiroz Amorim. – 2022.

70 f. : il. color.

Tese (doutorado) – Universidade Federal do Ceará, Centro de Ciências Agrárias, Programa de Pós-
Graduação em Agronomia (Fitotecnia), Fortaleza, 2022.

Orientação: Prof. Dr. Leonardo de Almeida Monteiro.

1. Inteligência artificial. 2. Tratores. 3. Rede de computadores. I. Título.

CDD 630

MARCELO QUEIROZ AMORIM

APLICAÇÃO DE TÉCNICAS DE AGRUPAMENTO E REDE NEURAL ARTIFICIAL EM
ACIDENTES COM MÁQUINAS AGRÍCOLAS

Tese apresentada ao Programa de Pós-Graduação em Engenharia Agrícola da Universidade Federal do Ceará, como requisito para obtenção do título de Doutor em Engenharia Agrícola. Área de concentração: Engenharia de Sistemas Agrícolas.

Aprovada em: 08/12/2022.

BANCA EXAMINADORA

Prof. Dr. Leonardo de Almeida Monteiro (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Karla Lúcia Batista Araújo
Centro Universitário Fametro (UNIFAMETRO)

Prof. Dr. Luís Gustavo Chaves da Silva
Universidade da Integração Internacional da
Lusofonia Afro-Brasileira (UNILAB).

Prof. Dr. Alexsandro Oliveira da Silva
Universidade Federal do Ceará (UFC)

Prof. Dr. Danilo Roberto Loureiro
Universidade Estadual do Ceará (UFC)

A Deus.

Aos meus pais, esposa e amigos.

AGRADECIMENTOS

Primeiramente agradecer a Deus pela proteção nos momentos mais difíceis em que necessitei de sua intervenção, recebendo o livramento e sendo direcionado pelo caminho certo, mesmo que tortuoso e mais longo.

À minha companheira, amiga e esposa Renata Freitas Fernandes por estar ao meu lado em toda essa caminhada, ajudando, incentivando e dando seu apoio, mesmo quando ninguém mais estava do meu lado.

Aos meus pais, Jose André Amorim e Maria do Carmo Queiroz Amorim pelo apoio incondicional, livre de qualquer julgamento, com a certeza de que eu estava no caminho certo em busca de alcançar meus objetivos.

À Instituição CAPES, pelo apoio financeiro com a manutenção da bolsa de auxílio, necessária para minha permanência no curso de pós-graduação, podendo se dedicar exclusivamente ao objeto de estudo.

Ao Prof. Dr. Leonardo de Almeida Monteiro, pela excelente orientação e dedicação em repassar os conhecimentos adquiridos ao longo de sua jornada na área de ensino e pesquisa na pós-graduação.

A todos os professores e colaboradores do Departamento de Engenharia Agrícola, que ao longo dessa jornada contribuíram, diretamente ou indiretamente, dentro ou fora da sala de aula, para transferência e obtenção de conhecimento.

Aos professores participantes da banca examinadora, Karla Lúcia Batista Araújo, Luís Gustavo Chaves da Silva, Alexsandro Oliveira da Silva e Danilo Roberto Loureiro; pelo tempo, pelas valiosas colaborações e sugestões que serão acatadas sempre que não violarem as normas da instituição.

A todos os Membros do Laboratório de Investigação de Acidentes com Máquinas Agrícolas – LIMA, que ajudaram na pesquisa mesmo que indiretamente.

Aos demais colegas da turma de doutorado, pelas reflexões, críticas e sugestões recebidas dentro e fora da sala de aula, que contribuíram para meu crescimento profissional e intelectual.

“Uma locomotiva, por mais potente que seja, não será capaz de andar se não tiver em cima dos trilhos.” (SILVA, 2016, p.122).

RESUMO

A utilização de máquinas tem se tornado cada vez mais comum, no entanto, isso tem elevado o número de acidentes, não só dentro das propriedades, mas também em estradas, rodovias e cidades, justificando a necessidade de estudá-los, identificar padrões, entender as causas e minimizar os riscos. Portanto, objetivou-se com esse estudo avaliar um conjunto de dados de acidentes com máquinas agrícolas em vias públicas e propriedades rurais para formar grupos similares, com caracterização e identificação de padrões com uso de redes neurais artificiais, mapas auto-organizáveis, combinadas a técnicas hierárquicas e não hierárquicas de agrupamento de dados, dendrograma, índice de db e coeficiente de k-means. Os dados foram obtidos de uma base de levantamento do LIMA no período de 2013 a 2022. As notícias de acidentes foram classificadas de acordo com sua região: região Sul, Região Sudeste, Região Centro Oeste, Região Nordeste e Região Norte. Período das ocorrências: madrugada, manhã, tarde e noite. quantidade de vítimas: sem vítimas, vítimas feridas, vítimas fatal e não informado. Local do acidente: via pública, propriedade rural e não informado. Causas do acidente: irregularidade do terreno, tomada de potência, uso inadequado do implemento, velocidade incompatível com a via, ultrapassagem insegura, falta de atenção, dormir ao volante, embriaguez, desobediência à sinalização e outras causas de acidentes. Tipos de acidentes: aprisionamento de membros, perda de membros, colisão, atropelamento, capotamento, queda do trator, outro e não informado. Tipos de implementos: Arado, grade, enxada rotativa, pulverizador, semeadora, colhedora, carreta, outros implementos e trator. Faixa etária do operador: Menos de 10 anos, de 11 a 20, de 21 a 30, de 31 a 40, de 41 a 50, de 51 a 60, de 61 a 70 e mais de 71 anos. A classe de cada indicador foi codificada formando uma matriz de dados quantitativos para análise. Para análises foram usadas técnicas de agrupamento e rede neural SOM. Depois de determinar a configuração da rede mais adequada, o treinamento foi automatizado, conforme programação das funções de entrada software utilizado. Para treinamento e simulação da rede neural artificial (rede SOM), após codificados os indicadores, foi utilizado o software MATLAB 2016, onde foi utilizada a ferramenta somtoolbox, responsável pelo treinamento da rede neural e simulação. A técnica de agrupamento combinada à rede neural de mapas auto- organizável mostrou-se como uma ferramenta poderosa na análise de dados de acidente, permitindo uma análise exploratória mais segura e completa.

Palavras-chave: inteligência artificial; tratores; rede de computadores.

ABSTRACT

The use of machines has become increasingly common; however, this has increased the number of accidents, which occur not only on the properties, but also on roads, highways and cities. Accidents involving tractors generate alarming data because, in some situations, they result in serious injuries or death, justifying the need to study them, identifying patterns, understanding the causes and minimizing the risks. Therefore, the objective of this study was to evaluate a dataset of accidents with agricultural machines on public roads and rural properties to form similar groups, characterization and identification of patterns using artificial neural networks, self-organizing maps, combined with techniques hierarchical and non-hierarchical data clustering, dendrogram, db index and k-means coefficient. Data were obtained from a LIMA survey database, with information from news of accidents involving tractors throughout the Brazilian territory in the period from 2013 to 2021. The news of accidents were classified according to their region: South region, Southeast region, Midwest Region, Northeast Region and North Region. Period of occurrences: dawn, morning; afternoon and night. Number of victims: no victims; injured victims, fatal victims and not informed. Location of accident: Via published, rural property and not informed. Causes of the accident: Irregular terrain, power take-off, improper use of the implement, speed incompatible with the road, unsafe overtaking, lack of attention, sleeping at the wheel, drunkenness, disobedience to signaling and other causes of accidents. Types of accidents: Imprisonment of limbs, loss of limbs, collision, being run over, overturning, falling from the tractor, other and not informed. Types of implements: Plow, harrow, rotary hoe, sprayer, seeder, harvester, cart, other implements and tractor. Operator's Age Range: Less than 10 years old, 11 to 20, 21 to 30, 31 to 40, 41 to 50, 51 to 60, 61 to 70 and over 71 years old. The class of each indicator was coded forming a matrix of quantitative data for analysis. For analysis, clustering techniques and SOM neural network were used. After determining the most suitable network configuration, training was automated, as per programming of the software input functions used. For training and simulation of the artificial neural network (SOM network), after coded indicators, the MATLAB 2016 software was used, where the somtoolbox tools were used, responsible for training the neural network and simulation. The clustering technique combined with the self-organizing neural network of maps proved to be a powerful tool in the analysis of accident fingers, allowing a safer and more complete exploratory analysis.

Keywords: artificial intelligence; tractors; computer network.

LISTA DE FIGURAS

Figura 1 -	Neurônio biológico com o corpo celular (região do núcleo, onde ocorre o metabolismo), dendritos do corpo celular (recebem os impulsos nervosos), e o axônio (prolongamento do neurônio que leva impulsos nervosos a outros neurônio ou células)	26
Figura 2 -	Esquema de uma arquitetura feedforward de camada simples aplicadas a classificação de padrões e filtragem de dados.....	28
Figura 3 -	Esquema de arquitetura feedforward de camadas múltiplas empregadas em problemas mais complexos como robótica e controle de processos industriais.....	29
Figura 4 -	Esquema de uma rede neural artificial de arquitetura recorrente ou realimentada.....	27
Figura 5 -	Esquema de arquitetura de uma estrutura reticulada com uma disposição espacial dos neurônios.....	30
Figura 6 -	Exemplo de resultado de um treinamento de uma rede neural por mapas auto organizados.....	34
Figura 7 -	Esquema de um dendrograma mostrando a relação hierárquicas entre os objetos avaliados.....	35
Figura 8 -	Esquema da apresentação gráfica do Índice de Davies-Bouldin (db), usado para validação dos agrupamentos avaliados.....	36
Figura 9 -	Esquema de um mapa de apresentação do coeficiente de k-mean com limites definidos em cores distintas.....	37
Figura 10 -	Universidade Federal do Ceará (UFC), localizada no município de Fortaleza no estado do Ceará.....	38
Figura 11 -	Fluxograma da coleta, tabulação, classificação e codificação dos dados de acidentes com máquinas agrícolas antes do treinamento da rede.....	39
Figura 12 -	Sequência do preenchimento do bloco de notas para importação dos dados para o software.....	45
Figura 13 -	Matriz unificada 14x15 (a), 15x15 (b) 20x20 (c) e 25x25 (d) com rótulos e hist inseridos na fase inicial de avaliação.....	50
Figura 14 -	Planos componentes dos acidentes com máquinas agrícolas em vias públicas e propriedades rurais para as regiões de ocorrência (a), tipo de	

	acidente (b), período da ocorrência (c) e causa do acidente (d).....	52
Figura 15 -	Planos componentes dos acidentes com máquinas agrícolas em vias públicas e propriedades rurais para quantidade de óbitos (e), facha etária do operador (f), local da ocorrência (g) e tipo de equipamento (h).....	54
Figura 16 -	Matriz unificada colorida (a), matriz unificada com hist inseridos (b), matriz unificada preta e branca com rótulos (c), matriz unificada colorida com hist e rótulos (d).....	56
Figura 17 -	Dendrograma dos acidentes com tratores em vias públicas e propriedades rurais.....	57
Figura 18 -	ndice de Devies-Bouldin (a), coeficiente de k-means com as classes separadas em cores (b), hist inseridos no gráfico do coeficiente de k-means (c) e frequência das classes inseridas no gráfico do coeficiente de k-means (d).....	58
Figura 19 -	Matriz unificada projetada das classes de k-means colorida (a), matriz unificada projetada das classes de k-means com hist inseridos preto e branco (b), matriz U projetada das classes de k-means com rótulos sem cores (c), matriz unificada projetada d.....	59

LISTA DE TABELAS

Tabela 1 -	Tabela 1 - Classificação e codificação de acordo com a região de ocorrência dos acidentes com máquinas agrícolas.....	40
Tabela 2 -	Classificação e codificação dos acidentes de acordo com a quantidades de vítimas.....	40
Tabela 3 -	Classificação e codificação dos acidentes de acordo com o indicador local do acidente.....	41
Tabela 4 -	Classificação e codificação dos acidentes de acordo com o indicador tipo de acidente.....	41
Tabela 5 -	Classificação e codificação dos acidentes de acordo com o indicador causas dos acidentes.....	42
Tabela 6 -	Classificação e codificação dos acidentes de acordo com o indicador faixa etária do operador.....	42
Tabela 7 -	Classificação e codificação dos acidentes de acordo com o indicador tipo de implemento acoplado.....	43
Tabela 8 -	Classificação e codificação dos acidentes de acordo com o indicador período do acidente.....	43
Tabela 9 -	Resumo das classes codificadas referentes aos indicadores da região de ocorrência, período do acidente, quantidade de vítima, local do acidente, tipo de acidente, causa do acidente, faixa etária do operador e tipo de equipamento.....	44
Tabela 10 -	Erro de quantização e topográfico de acordo com o tamanho das redes trinadas no processo de aprendizagem.....	51
Tabela 11 -	Detalhamento dos grupos dos acidentes com tratores e máquinas agrícolas em via públicas e propriedades rurais.....	60

SUMÁRIO

1	INTRODUÇÃO.....	15
2	REVISÃO DE LITERATURA.....	18
2.1	Tratores agrícolas e sua importância na agricultura.....	18
2.2	Acidentes com tratores e máquinas agrícolas.....	20
2.2.1	<i>Acidentes com tratores agrícolas em propriedades rurais.....</i>	22
2.2.2	<i>Acidentes com tratores agrícolas em vias públicas.....</i>	24
2.3	Redes neurais artificiais.....	26
2.3.1	<i>Tipos de redes neurais.....</i>	27
2.4	Técnicas agrupamento de dados.....	32
2.4.1	<i>Mapas auto-organizados.....</i>	33
2.4.2	<i>Dendrograma.....</i>	34
2.4.3	<i>Índice de Davies-Bouldin (db).....</i>	36
2.4.4	<i>Coeficiente de k-means.....</i>	37
3	MATERIAL E MÉTODOS.....	38
3.1	Local da pesquisa.....	38
3.2	Obtenção dos dados.....	38
3.3	Processamento dos dados obtidos.....	39
3.3.1	<i>Classificação das regiões de ocorrência.....</i>	39
3.3.2	<i>Classificação e codificação do indicador quantidade de vítimas.....</i>	40
3.3.3	<i>Classificação e codificação do indicador local do acidente.....</i>	40
3.3.4	<i>Classificação e codificação do indicador tipo de acidente.....</i>	41
3.3.5	<i>Classificação e codificação do indicador causas de acidentes.....</i>	41
3.3.6	<i>Classificação e codificação do indicador faixa etária do operador.....</i>	42
3.3.7	<i>Classificação e codificação do indicador tipo de implemento.....</i>	42

3.3.8	<i>Classificação e codificação do indicador período do acidente.....</i>	43
3.4	Avaliação dos dados.....	45
3.4.1	<i>Treinamento das redes neurais.....</i>	45
3.4.2	<i>Dendrograma.....</i>	48
3.4.3	<i>Índice de Devies-Bouldin (DB).....</i>	48
3.4.4	<i>Coeficiente k-means.....</i>	49
4	RESULTADOS E DISCUSSÃO.....	50
5	CONCLUSÃO.....	63
	REFERÊNCIAS.....	64

1 INTRODUÇÃO

O uso de máquinas agrícolas tem tornando-se cada vez mais comum e indispensável no campo, principalmente quando levamos em consideração a demanda de alimentos dos grandes centros urbanos e as pesadas, repetitivas e estressantes tarefas envolvidas na produção de alimento, exigindo uma fonte de potência eficiente e versátil como o trator.

O trator agrícola pode ser caracterizado como principal fonte de potência no meio rural, sendo responsável pela maioria das vendas no mercado de máquinas agrícolas. Dos tratores comercializados no Brasil, as regiões Sul e Sudeste são as maiores consumidoras, sendo responsáveis por elevadas porcentagens de máquinas vendidas, seguidas do Centro-Oeste, Norte e Nordeste.

Essa expressiva comercialização de tratores, impulsionada pelas grandes demandas de alimentos dos maiores centros urbanos, exportação e crescimento do agronegócio, têm ocorrido com uma velocidade maior que o esperado, resultando em elevado número de acidentes com tratores e máquinas agrícolas no campo, rodovias ou mesmo centros urbanos.

A mecanização na agricultura tem como objetivos aumentar a produtividade, melhorar a qualidade das operações e o bem-estar do operador durante a jornada de trabalho. No entanto, é importante destacar também os problemas que isso representa, como os malefícios ocasionados pelo mal uso da máquina.

Os acidentes no trabalho representam importância social e econômica muito grande, pois estudos estatísticos demonstram a gravidade do problema, seja pela incidência, idade dos acidentados no trabalho, ou versatilidade da máquina e o seu crescente uso na agricultura que contribuíram para elevar o número de acidentes com vítimas graves no meio rural.

Outro aspecto que tem que ser levado em consideração é que os acidentes com máquinas agrícolas estão se tornando cada vez mais comuns, não só na zona rural, mas também em rodovias na zona urbana, com tráfego constante, seja para mudança do local do trabalho a ser realizado ou para transporte de produtos agrícolas e insumos em geral aplicados nas lavouras.

O estudo de acidentes envolvendo máquinas agrícolas também não é uma tarefa muito fácil, devido a dinâmica que um acidente pode ou não acontecer, seja no campo ou zona

urbana, por motivos internos, inerentes à máquina, como: defeito mecânico, ergonômicos ou mesmo externos, como: via de circulação, condições climáticas, terreno, operador e etc.

Dentro de uma propriedade rural, as causas de acidentes podem mudar, quando comparado com as vias de circulação, podendo ocorrer em função das condições do terreno, condições das máquinas, tipo de equipamento, capacidade e experiência do operador, desrespeito às normas de segurança é condição climática.

Do ponto de vista estatístico, tamanha dinâmica e aleatoriedade, não pode ser só avaliada por meios tradicionais como teste de média ou estatística descritiva, pois pode não refletir a natureza dos dados.

O uso de técnicas computacionais, como redes neurais artificiais (RNA) para agrupar dados, no entanto, apresentam-se como alternativa viável por conseguir agrupar as classes mais frequentes e identificar suas interações, mesmo quando a dinâmica das ocorrências é grande.

A técnica da RNA permite extrair informações de um banco de dados com muitas informações, variáveis com características contínuas e também categóricas, obtendo padrões entre elementos de entrada e um de interesse, permitindo extrair informações e prever resultados.

Dentro deste sistema, os sinais de entrada são fornecidos para outros neurônios como parâmetros iniciais do processo de aprendizagem, sendo variáveis de processadores interligados, operando em paralelo para executar uma função com seus códigos previamente estabelecidos.

As RNA possuem modelos diferentes, em que a diferença em cada modelo é estabelecida através de características básicas de cada uma, como o tipo de entrada (binário e intervalar), conexão (forma de alimentação à frente, retroalimentação e forma de alimentação competitiva) e o tipo de aprendizado (aprendizado supervisionado, auto aprendizado ou aprendizado não supervisionado da rede).

Avaliação estatística tradicional de dados que não são numéricos, com os dados de acidentes com máquinas agrícolas, trazem muitas dificuldades para análise e requer muitas suposições e muitos testes sobre a distribuição dos dados avaliados. Podendo ser considerados nessa afirmativa, os testes de agrupamentos hierárquicos e não hierárquicos.

Uso de técnicas computacionais como os mapas auto-organizados é uma alternativa válida, podendo ser combinada com outras técnicas de agrupamentos hierárquicos e não hierárquicos como dendrograma e coeficiente de k-means para agrupar dados e avaliar similaridades ou mesmo interação nos grupos mais frequentes em um conjunto de dados.

O dendrograma como técnica de agrupamento, reunir objetos semelhantes em um conjunto de dados de entrada, essa semelhança é encontrada pela distância entre pares de objetos, quando dados com menor distância entre eles são encontrados, os mesmos são colocados no mesmo grupo, devido ao seu grau de semelhança. Para medir o coeficiente de distância pode ser usada várias metodologias existentes, no entanto a distância euclidiana é a mais aplicada.

O método de agrupamento por coeficiente de k-means busca padrões entre os objetos de estudo, agrupando os mesmos pelo seu grau de semelhança formando os grupos conforme são encontradas similaridades que permitam a formação de agrupamentos. As representações desses grupos são realizadas pelas médias numéricas, centroides, de todos os objetos que compõe os agrupamentos formados.

Portanto, objetivou-se com esse estudo avaliar um conjunto de dados de acidentes com máquinas agrícolas em vias públicas e propriedades rurais para formar grupos similares, com caracterização e identificação de padrões com uso de redes neurais artificiais, mapas auto-organizáveis, combinadas à técnicas hierárquicas e não hierárquicas de agrupamento de dados, dendrograma, índice de db e coeficiente de k-means.

2 REVISÃO DE LITERATURA

2.1 Tratores agrícolas e sua importância na agricultura

Na agricultura moderna, com elevado uso de insumos agrícolas, abrangendo grandes áreas cultivadas para atender a alta demanda dos grandes centros urbanos, indústria e exportação, a força humana ou mesmo animal já não são mais as principais fonte de potência para girar essa enorme engrenagem.

De acordo com Hettwer (2022), a agricultura moderna surgiu principalmente no século XX, quase que extraordinariamente na segunda metade do século, com a utilização maciça de novas tecnologias que aumentaram a produtividade no Brasil e no mundo.

Segundo Oliveira (2016), esse salto tecnológico ficou conhecido como mundialização da agricultura moderna, que incorpora novos procedimentos com o uso intensivo do solo com adoção de produtos químicos variados, sementes transgênicas, sensoriamento remoto e intensa mecanização das lavouras.

Esse modelo de agricultura é fundamentado na produção de grandes volumes voltada aos mercados interno e externo de alta escala, principalmente produção de commodities agrícolas cotadas nos mercados internacionais, com pouca mão de obra humana ou animal empregada (HETTWER, 2022), com destaque para mecanização.

O trator no contexto da agricultura atual, digital, conectada e mecanizada, é a principal fonte de potência, necessário em operações que vão além do preparo inicial do solo, tratamentos culturais, colheita e pós-colheita (RINALDI *et al.*, 2016).

Tamãha usabilidade fez com que o trator agrícola em 2020 no Brasil, representasse mais 74% das vendas no mercado de máquinas (RESTA, 2022), destacando ainda nesse cenário seu mercado de máquinas agrícolas aquecido o ano todo, principalmente Sul e Sudeste.

Na agricultura mundial, o Brasil tem posição de destaque, sendo considerado por muitos, como o celeiro do mundo, devido suas grandes quantidades de terras agricultáveis e condições climáticas favoráveis, com destaque para as grandes áreas mecanizadas em todo país.

De acordo com Figueira e Galache (2022), Brasil, Argentina e Estados Unidos da América (EUA), são os maiores produtores e exportadores de grão de soja, esses países são os maiores do mundo, com alto grau de mecanização para atender as demandas geradas pela cultura no campo.

Dados da Food and Agriculture Organization of the United Nations (FAO, 2019), Brasil, Argentina e Estados Unidos da América (EUA), em média representaram o equivalente a 80,6% da produção de todo mundo, o que demanda muitas máquinas nas lavouras de grãos para movimentar o setor.

Dos tratores agrícolas comercializados em todo o país, no ano de 2020, as regiões Sul e Sudeste foram as maiores consumidoras desse tipo de máquinas, sendo responsáveis por mais de 63% das vendas nos pontos de comercialização, seguidas do Centro-Oeste com 20%, Norte com 6% e Nordeste com 10% (ANFAVEA, 2022).

Nesse contexto, não podemos esquecer da importância da agricultura familiar que abrange parte do mercado, abastecendo principalmente o comércio local, gerando emprego e renda em todo território nacional, absorvendo parte das novas tecnologias do mercado de máquinas agrícolas.

De acordo com o Ministério da Agricultura, Pecuária e Abastecimento (MAPA, 2019), a agricultura familiar é o pilar central da economia de 90% dos municípios do país com até 20 mil habitantes, compondo 35% do produto interno bruto nacional (PIB) e ocupando 40% da população economicamente ativa do Brasil.

Na agricultura moderna, a agricultura familiar também tem refletido a crescente mecanização, movimentando o mercado de máquinas de menor potência, impulsionado pelos incentivos governamentais, sendo amplamente absorvida, modernizando as propriedades de menor porte.

Para Lopes *et al.* (2020) o uso de máquinas agrícolas tem se tornado cada vez mais comum, mesmo na agricultura familiar, pois é indispensável nas propriedades rurais em decorrência do crescente aumento da população no mundo e da necessidade de se produzir mais alimento, exigindo uma agricultura modernizada para atender a demanda.

De acordo com Baesso *et al.* (2018) a mecanização na agricultura tem como objetivos aumentar a produtividade, melhorar a qualidade das operações e o bem-estar do operador durante a jornada de trabalho.

No entanto, é importante destacar os problemas que resultam do uso demasiado, sem preparo do operador, que muitas vezes contribuem para acidentes em zonas rurais, urbanas, rodovias federais e estaduais do Brasil e do mundo.

Para Macedo *et al.* (2020), as condições de risco para os operadores oferecidos por essas máquinas, representa grande perigo, pois os acidentes com máquinas agrícolas costumam causar lesões graves, envolvendo mais de uma pessoa.

Outro fato relevante que tem preocupado muito as autoridades e órgãos

competentes, é o elevado número de máquinas agrícolas envolvidas em acidentes nos grandes centros urbanos, rodovias estaduais e federais.

2.2 Acidentes com tratores e máquinas agrícolas

O elevado número de tratores no campo, devido a crescente mecanização das lavouras e versatilidade do trator, juntamente com a falta de preparo para operar a máquina, tem elevado o número de acidentes, que ocorrem não só dentro das propriedades, mas também em estradas, rodovias e cidades (PEREIRA *et al.*, 2021).

Essa preocupação a cada dia tem ficado maior, devido a grande quantidade de acidentes que vem ocorrendo, principalmente em via públicas, próximas de centros urbanos envolvendo pedestre, ciclistas, motociclista ou mesmo carros de passeios gerando um número absurdo de vítimas.

De acordo com Guinot *et al.* (2021) o trabalho com tratores na agricultura é altamente vulnerável a ocorrências de acidentes, podendo envolver uma ou várias vítimas com ferimentos graves ou fatais e gerar grandes danos econômicos.

Além dos danos econômicos, o que mais preocupa nas ocorrências de acidentes com máquinas agrícolas é a gravidade das lesões causadas às vítimas com ferimentos graves, perdas de membros ou em muitos casos, tirando a vida dos envolvidos sem a possibilidade de socorro.

De acordo com a Organização Internacional do Trabalho (OIT, 2004), um em cada três acidentes de trabalho na zona rural, está relacionado com máquinas agrícolas, resultando em incapacidade do trabalhador, ou seja, na maioria dos acidentes envolvendo máquinas agrícolas, os danos causados às vítimas resultam em ferimentos graves ao indivíduo, podendo levar à morte.

O trator, por ser uma máquina robusta de grande porte, pesada, com muitas partes rígidas de ferro maciço, projetada para resistir aos trabalhos repetitivos e exaustivos no campo, acabam contribuindo mais ainda para a severidade das lesões, pois muitas de suas parte ficam expostas.

Para Bellochio *et al.* (2018), os acidentes no trabalho representam importância social e econômica muito grande, pois estudos estatísticos demonstram a gravidade do problema, seja pela incidência, idade dos acidentados no trabalho, ou versatilidade da máquina e o seu crescente uso na agricultura que contribuíram para elevar o número de acidentes com vítimas graves no meio rural.

Quando usado demasiadamente, o trator agrícola pode gerar muitos malefícios, entre eles, podemos citar a emissão de poluente, compactação do solo, ruído elevado, vibração e acidentes com máquinas agrícolas.

Todos esses malefícios podem resultar em danos à saúde do operador ou terceiros envolvidos na atividade agrícola ou não (SANTOS *et al.*, 2022), pois muitas vezes quando ocorrem em vias públicas podem envolver ciclistas, motociclistas ou mesmo carros de passeio e outros veículos coletivos de grande porte.

Para Macedo *et al.* (2018), as máquinas agrícolas estão diretamente relacionadas aos altos índices de poluição atmosférica associada à agricultura. Na china, 81 % das emissões de poluentes por veículos automotivos são gerados por veículos agrícolas (LANG *et al.*, 2018).

Fernandes *et al.* (2022), afirmam em seu estudo que os operadores de máquinas agrícolas são submetidos à várias situações de alto risco, podendo ser citado a exposição a ruídos elevados, podendo ocasionar influência na produtividade dos tratoristas nas atividades no campo e danos a sua saúde auditiva e física.

Para Santos *et al.* (2021), um problema resultante do uso de máquinas agrícolas que pode causar muitos danos à saúde do operador é a vibração, que pode ser resultado da vibração da máquina ou mesmo da superfície do terreno.

Ainda que as emissões de poluentes, ruído elevado e vibração demasiada possam causar danos aos operadores, pouco se comparam à letalidade dos acidentes com máquinas agrícolas que resultam em morte ou ferimentos graves com alta letalidade (GUIMARÃES *et al.*, 2022).

De acordo com Sousa *et al.* (2022), entre os principais causadores de acidentes rurais, podem ser destacados a falta de condições mínimas de segurança na plataforma de operação, condições de trabalho insalubres, ausência de proteção individual, utilização incorreta de equipamentos e intoxicação por fitossanitários.

Outro aspecto que tem que ser levado em consideração é que os acidentes com máquinas agrícolas estão se tornando cada vez mais comuns, não só na zona rural, mas também em rodovias na zona urbana, com ao tráfego constante, seja para mudança do local do trabalho a ser realizado ou para transporte de produtos agrícolas e insumos em geral (GKRITZA *et al.*, 2010).

2.2.1 Acidentes com tratores agrícolas em propriedades rurais

A ocorrência de acidentes com máquinas agrícolas em propriedades rurais sempre ocorreu com muita frequência, no entanto, nos últimos anos essa frequência tem sido muito maior, mesmo com o aporte de novas tecnologias estruturais, ergonômicas e operacionais incorporadas à máquina (GUINOT *et al.*, (2021).

O Brasil se tornou um dos maiores produtores agrícolas do mundo, intensificando uso de tecnologia na agricultura, no entanto, mesmo com adequação do trabalho para a modernidade, passou a apresentar, apesar de poucas estatísticas, uma grande quantidade de acidentes (SANTOS *et al.*, (2022).

Acidentes em propriedades rurais, do ponto de vista do agente causador, é um assunto muito complexo, pois os acidentes podem acontecer em função das condições mecânicas da máquina, condições físicas e técnicas do operador, condições do terreno, condições climáticas ou mesmo envolvendo mais de um desses fatores.

Dentro de uma propriedade rural, as causas de acidentes podem mudar, quando comparado com as vias de circulação, podendo ocorrer em função das condições do terreno, condições das máquinas, tipo de equipamento, capacidade e experiência do operador, desrespeito às normas de segurança e condição climática (BELLOCHIO *et al.*, (2018).

Os acidentes com tratores e máquinas agrícolas poderiam ser evitados se as máquinas possuíssem dispositivos para aumentar a segurança e se os operadores fizessem uso de equipamentos de proteção individual seguindo às recomendações de segurança na execução das atividades (BAESSO *et al.*, 2018).

De acordo com Macedo *et al.* (2020), o uso inadequado de máquinas agrícolas no campo, não seguindo as recomendações de segurança, apresenta grande potencial para ocorrência de acidentes, recomendando em seu estudo que não ocorra o tráfego de máquinas à noite, devido à grande possibilidade de ocorrência de colisão com mortalidade dos envolvidos.

De acordo com Pereira *et al.* (2020), os trabalhadores rurais com idade acima de 50 anos, manifestaram maior resistência quando comparados aos mais jovens nas abordagens para seus estudos em segurança no trabalho, constatando que a escolaridade e a experiência de trabalho trazem maior conhecimento sobre esses aspectos.

Outro dado alarmante apresentado por Baesso *et al.* (2018), na conclusão de sua pesquisa foi que 66,10% dos operadores não faziam uso do cinto de segurança, mesmo tendo esse item de segurança em tratores com estrutura de proteção contra o capotamento disponível.

Guinot *et al.* (2020), fazendo o diagnóstico de acidentes de trabalho com tratores

agrícolas no estado do Rio Grande do Sul, pode constatar que 62% das causas de acidentes ocorreram devido a atos inseguros, com 33% dos óbitos ocorrendo devido ao capotamento ou tombamento, fato esse, muitas vezes atribuído à condição do terreno.

Para Zawacki (2017) o risco de acidentes envolvendo tratores de alta potência, por exemplo, pode estar relacionado à falta ou mal uso de equipamentos de proteção individual, equipamentos não adequados nas operações, características ergonômicas desfavoráveis e imprudência do operador.

De acordo com os dados expostos por Macedo *et al.* (2018), umas das causas mais frequentes de acidentes com máquinas agrícolas foi a falta de atenção e defeito mecânico, contribuindo para a ocorrência de acidente, alertando para a importância das manutenções preventiva, preditiva e corretiva.

Ferreira *et al.* (2018), analisando as causas de acidentes com tratores na região do alto sertão sergipano do nosso país, mostrou que os acidentes com maior frequência estão relacionados à ocorrência de colisões e ao uso do eixo cardã, citando outros fatores, como o cansaço devido grandes jornadas de trabalho e ingestão de bebidas alcoólicas.

Nessa perspectiva, Macedo *et al.* (2018), recomendam enfaticamente evitar o tráfego de máquinas agrícolas no período da noite para evitar colisões, grandes jornadas de trabalho que possam causar fadiga e conseqüentemente contribuir para ocorrência de acidentes com máquinas agrícolas.

Outra constatação importante sobre a ocorrência de acidentes com máquinas agrícolas ocorridos no campo é a dificuldade na prestação de socorro, pois muitas vezes ocorrem longe de casa, em locais de difícil acesso e sem ninguém para prestar socorro adequadamente.

Guinot *et al.* (2021), fazendo o diagnóstico de acidentes de trabalho com tratores agrícolas no estado do Rio Grande do Sul, alerta em seus estudos para a dificuldade da prestação de socorro, em função da distância entre as propriedades rurais e os hospitais que geralmente estão localizados em grandes centros urbanos.

Ainda sobre acidentes com máquinas agrícolas, não podemos esquecer que eles já não estão mais só ocorrendo no campo, nas propriedades rurais, mas também em vias públicas como rodovias estaduais, rodovias federais, regiões metropolitanas, pequenas e grandes cidades.

2.2.2 *Acidentes com tratores agrícolas em vias públicas*

De acordo com Sousa *et al.* (2022), a utilização de máquinas agrícolas se dá praticamente em todas as etapas do ciclo de produção, preparo da área para deixar limpa, preparo inicial do solo, semeadora e plantio, tratos culturais, colheita e pós colheita, podendo se estender até a etapa do beneficiamento e transporte.

No entanto, a presença de máquinas em vias públicas (rodovias) está associada a necessidade de deslocamento das máquinas para atividades no campo de uma propriedade para outra, principalmente em rodovias estaduais e federais. Jarén *et al.* (2021), estudando acidentes com tratores na Espanha durante a última década também reforça a constatação.

Nas pequenas e grandes cidades a presença de máquinas agrícolas é menor, sendo o mais comum os tratores empregados na construção civil, como as retroescavadeiras por exemplo, observação colaborada por Facchinetti *et al.* (2022), estudando fatalidades relacionadas a capotamento de trator na Itália nos últimos 12 anos.

De todo modo, a circulação dessas máquinas em vias públicas representa um grande risco para a comunidade em geral, pois se deslocam com uma velocidade menor que os veículos de passeio, fator agravante para ocorrência de acidentes em vias públicas com máquinas agrícolas (MONTEIRO E ALBIEIRO, 2013).

Bellochio *et al.* (2018), em seu estudo destacou que mais de 50% dos acidentes que acontecem em vias públicas, estão relacionados com máquinas agrícolas, dando destaque para o Sul, Sudeste e Centro Oeste, associando a essas regiões, uma maior frota de máquinas agrícolas.

Fator mais alarmante ainda é trazido por Baesso *et al.* (2018), ressaltando em seu estudo que os riscos das atividades com maquinário agrícola são maiores que os oferecidos por outros setores, com alta letalidade e envolvem muitas pessoas, principalmente quando acontecem em vias de circulação com veículos de passeio.

Greenan *et al.* (2016), estudando a ocorrência de acidentes com máquinas em zonas urbanas norte americanas, observaram que o aumento no número da média anual de veículos circulando diariamente nas rodovias de Iowa teve relação direta com o aumento do risco de colisões com máquinas resultando em vítimas com ferimentos graves.

Além do aumento do risco ocasionado pelo tráfego de máquinas, acidentes envolvendo tratores apresentam uma relação maior de vítimas acidentadas em estado grave ou mesmo que vieram a óbito por acidente, se comparado com veículos de passeio, mostrando o grau de risco que esta eventualidade representa devido sua gravidade (CESVI BRASIL, 2012).

Para Macedo (2014), a fadiga dos operadores em conjunto com o estresse do trânsito, torna os operadores mais vulneráveis a ocorrências de acidentes. No entanto, diversos fatores podem contribuir para a ocorrência de um acidente em via pública ou propriedade rural, podendo ser citada condição da estrada, janela de plantio ou período de colheita, horário do acidente e entre outras.

De acordo com Sousa *et al.* (2022), a condição das estradas é um fator que muito contribui para a ocorrência de um acidente, podendo resultar em vítimas com ferimentos graves que pode levar a morte e perda total da máquina ou veículos envolvidos no acidente.

Para Macedo *et al.* (2020), a janela de plantio ou período de colheita, horário do dia em que a operação está sendo executada, condições climáticas, são fatores que devem ser levados em consideração quando o objetivo for prevenir e evitar acidentes com máquinas agrícolas.

O mesmo foi observado pelo estudo realizado por Baesso *et al.* (2018), destacando que a ergonomia envolvendo a máquina agrícola é de extrema importância, independentemente de sua aplicação, pois caso contrário pode contribuir com a fadiga do operador e conseqüentemente provocar um acidente quando somado a outros fatores.

Em estudos realizados por Monteiro (2012), com caracterização de acidentes em notícias veiculadas à internet, o autor verificou como sendo a principal causa de acidentes a perda de controle da máquina pelo operador com um alto percentual, sendo a falta de atenção outra causa com percentual elevado.

Em estudos realizados por Monteiro e Albiero (2013), foi possível verificar que devido a inúmeras facilidades proporcionadas pelo trator, o operador deixa de seguir certas práticas de segurança durante as operações agrícolas que poderiam evitar a ocorrência de muitos acidentes.

Boyaci e Yildiz *et al.* (2021), afirmam ainda em seus estudos que o não seguimento do operador a práticas de segurança, principalmente devido ao excesso de confiança dos condutores das máquinas, podendo resultar em acidentes graves e com muitas vítimas envolvidas.

Macedo (2018) e Lima (2016), relatam a importância do estudo e conhecimento das causas que envolvem os acidentes, sendo necessário o desenvolvimento de novas tecnologias para entender e prevenir acidentes envolvendo tratores agrícolas nas vias de circulação e propriedades rurais.

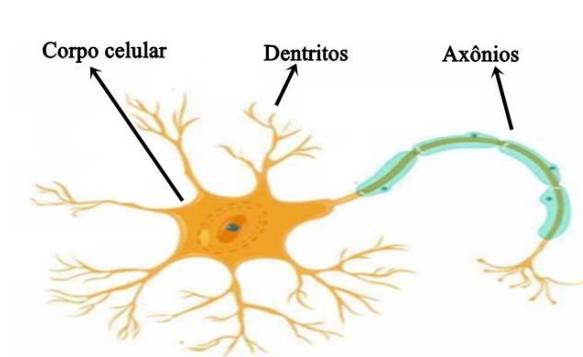
Logo o uso de técnicas computacionais como redes neurais artificiais pode ser uma alternativa, principalmente quando combinadas a técnicas hierárquicas e não hierárquicas

de agrupamento de dados, dendrograma, índice de db e coeficiente de k-means, tudo para proporcionar o melhor agrupamento de dados.

2.3 Redes neurais artificiais

A rede neural artificial (RNA) pode ser considerada como uma técnica computacional que simula a maneira como nosso cérebro aprende, extraindo informações de um banco de dados com muitas informações (FIGURA 1), de variáveis com características contínuas e também categóricas para obter padrões entre elementos de entrada e um de interesse, permitindo extrair informações e prever resultados (COSENZA *et al.*, 2017).

Figura 1 - Neurônio biológico com o corpo celular (região do núcleo, onde ocorre o metabolismo), dendritos do corpo celular (recebem os impulsos nervosos), e o axônio (prolongamento do neurônio que leva impulsos nervosos a outros neurônio ou células)



Fonte: Cosenza *et al.*, 2017).

De acordo com Godarzi *et al.* (2014), um neurônio biológico obtém as informações de entrada através de uma fonte externa, depois combina esses dados com operações não lineares e produz uma resposta com base no conhecimento absorvido, reproduzindo padrões necessários, sendo esse comportamento reproduzido em um neurônio artificial.

Para Kankal *et al.* (2011), os neurônios artificiais atuam semelhante ao neurônio humano, comunicam-se por meio de número de ligações externos formando uma ponderada rede. Essa poderosa rede permite extrair muitas informações importante, mesmo que seja uma base de dados gigantes e que aparentemente não digam nada quando usada outra metodologia estatística.

De acordo com Silva *et al.*, (2018) e Carvalho *et al.*, (2016), dentro deste sistema, os sinais de entrada são fornecidos para outros neurônios como parâmetros iniciais, sendo variáveis de processadores interligados, operando em paralelo para executar uma função.

Os neurônios são organizados em complexas estruturas de redes formadas por diversas camadas contendo um número estabelecido de neurônios. O aspecto mais interessante desta metodologia é que na modelagem, é utilizado o processo de aprendizagem por treinamento a partir de dados fornecidos (MULERO *et al.*, 2017).

De acordo com Claro *et al* (2018), as RNA possuem modelos diferentes, em que a diferença em cada modelo é estabelecida através de características básicas de cada uma, como o tipo de entrada (binário e intervalar), conexão (forma de alimentação à frente, retroalimentação e forma de alimentação competitiva) e o tipo de aprendizado (supervisionado, auto aprendizado ou não supervisionado).

Dentre as redes de alimentação competitiva e não supervisionadas pode ser citada o mapa auto organizável, que apresenta uma grande capacidade de agrupar dados e extrair informações de mega base de dados, podendo ainda ser combinada com outras técnicas de agrupamento de dados.

2.3.1 Tipos de redes neurais

Existem diferentes tipos de redes neurais artificiais, com arquiteturas e topologias que as distinguem, bem como as formas de treinamento Silva *et al.* (2022). Com isso o treinador da rede tem várias alternativas de tratamento e avaliação dos dados, podendo escolher conforme a resposta esperada.

A arquitetura de rede neural se refere à disposição dos neurônios, seguindo as conexões um em relação ao outro. Já a topologia são as diferentes composições da estruturais com número variáveis de neurônios nas camadas de iniciais, centrais e de saída da rede neural artificial (RICARDO, 2022).

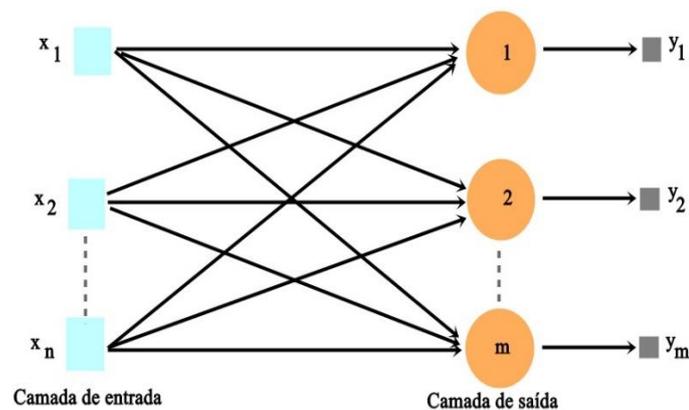
O treinamento de uma rede é basicamente obter valores de pesos e limiares baseados em uma amostra de dados de entrada, fazendo com que qualquer outra amostra apresentada futuramente seja corretamente classificada e agrupada conforme grau de aprendizado da rede (CARMO, 2022).

Existem muitos tipos de redes Palma (2022), sendo as principais arquitetura feedforward de camada simples, feedforward de camadas múltiplas, recorrente ou

realimentada e estrutura reticulada. Quanto à topologia pode ser perceptron, adaline, perceptron multicamadas, redes de base radial, hopfield e perceptron multicamadas com realimentação, kohonen e etc., dependendo da arquitetura.

A arquitetura feedforward de camada simples tem a camada de entrada associada direta a um ou mais neurônios, gerando a resposta de saída dos dados (FIGURA 2), com o fluxo de dados seguindo em direção à camada de saída da rede (BARONTE, 2022), podendo ser do tipo Perceptron ou Adaline.

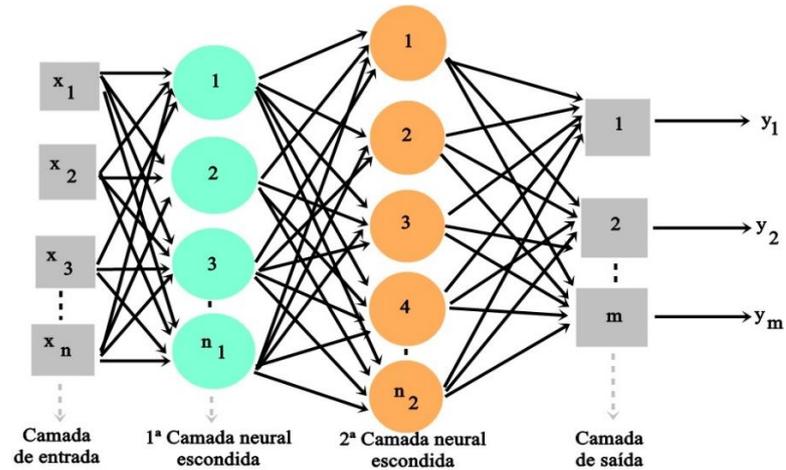
Figura 2 - Esquema de uma arquitetura feedforward de camada simples aplicadas a classificação de padrões e filtragem de dados



Fonte: Baronte (2022).

A arquitetura feedforward de camadas múltiplas, diferente das feedforward de camadas simples, é constituída por camadas escondidas de neurônios (BARONTE, 2022), podendo ser apenas uma camada escondida ou mais (FIGURA 3), esse tipo de rede pode ser perceptron multicamadas, redes de base radial.

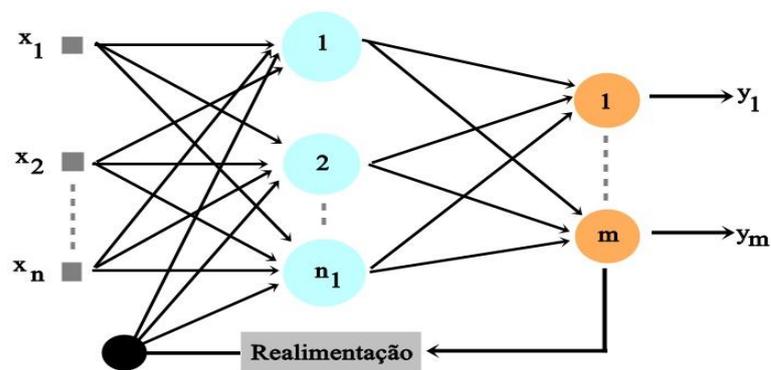
Figura 3 - Esquema de arquitetura feedforward de camadas múltiplas empregadas em problemas mais complexos como robótica e controle de processos industriais



Fonte: Baronte (2022).

Rede de arquitetura recorrente ou realimentada, a realimentação é feita com sinais de entrada para outros neurônios dentro da rede (SOUZA, 2022), no processamento de sistemas complexos variantes no tempo (FIGURA 4), como as previsões de séries temporais, otimização estruturada, identificação de sistemas e controle de processos em diversos setores industriais, podendo ser do tipo perceptron multicamadas com realimentação e hopfield.

Figura 4 - Esquema de uma rede neural artificial de arquitetura recorrente ou realimentada

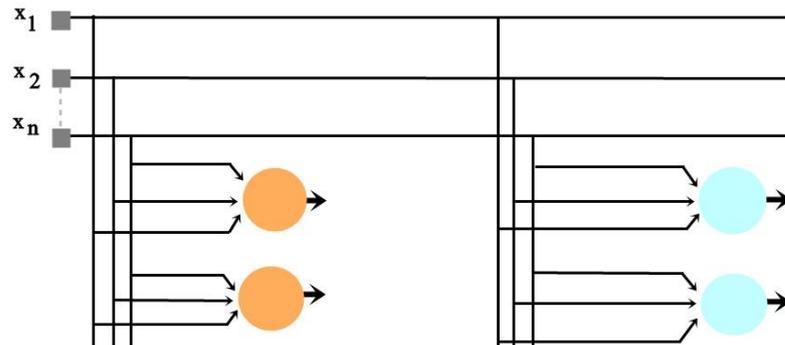


Fonte: Souza (2022).

Já a arquitetura de estrutura reticulada tem uma disposição espacial dos neurônios (FIGURA 5), para extração de características espacial do sistema, em outras palavras, sua localização espacial serve de ajuste de pesos e limiares da rede (SOUZA, 2022). Logo, são

aplicadas em problemas de agrupamento, reconhecimento de padrões e etc., sendo o tipo mais usado o Kohonen (Mapas auto organizável).

Figura 5 - Esquema de arquitetura de uma estrutura reticulada com uma disposição espacial dos neurônios



Fonte: Souza (2022).

O tipo de treinamento que a rede neural artificial vai ser submetida é muito importante e pode ser de vários tipos, podendo ser supervisionado, não supervisionado, com reforço, lote padrões (off-line) e padrão por padrão (on-line).

O treinamento supervisionado de redes neurais artificiais dispõe dos dados amostrais e das respectivas saídas dos dados desejadas, para que os pesos e limiares possam ser ajustados de forma contínua pelo algoritmo de aprendizagem que está sendo treinado (FURTUOSO *et al.*, 2022).

Os algoritmos no treinamento supervisionado podem ser agrupados em regressões e classificações matemáticas, que envolvem variáveis finais de forma contínuas ou discretas, respectivamente, gerando uma resposta de acordo com os dados inseridos (TIPIRISETTY, 2018).

Quando não supervisionado, os dados de saída têm a capacidade de se auto-organizar em relação às características dos dados avaliados e assim identificar subgrupos similares, sendo os pesos e limiares ajustados pelo algoritmo de aprendizagem refletindo essas características (FURTUOSO *et al.*, 2022).

Para o pesquisador Tipirisetty (2018), o aprendizado não supervisionado de redes neurais artificiais, consiste basicamente em atribuir padrões a dados amostrais de entrada, sendo divididos em algoritmos de agrupamento e de associação conforme seu grau de similaridade conforme parâmetros estabelecidos.

De acordo com Matos *et al.*, (2021), no treinamento com reforço, seu algoritmo visa ajustar os pesos e limiares com base nas informações resultantes da interação com o sistema mapeado no treinamento, reforçando as respostas. Esse tipo de treinamento é muito similar ao treinamento supervisionado.

Segundo Batista (2022), o treinamento por lote padrões off-line, apresenta no treinamento primeiramente todo o conjunto de dados amostrais para depois se ajustar os pesos e limiares da rede no processo de treinamento.

Já o treinamento padrão por padrão on-line, os pesos e limiares são todos ajustados depois de apresentada cada amostra, esse procedimento permite que a amostra seja descartada posteriormente, conforme característica e confiabilidade dos dados (BAISTA, 2022).

Para Roque (2016), a rede neural de alimentação à frente, também conhecida como feedforward, é a rede neural que seguindo as direções de ligações sinápticas estabelecidas, a partir de qualquer unidade, chega a uma unidade de saída de dados, mesmo não estando ligada a outra unidade da rede, sem retroalimentações.

Zuppini (2018), afirma que as redes neurais com retroalimentação, seja ela feedback ou redes de ciclos, possuindo neurônios dinâmicos com retardo, também são chamadas de redes recorrentes, são redes que em seu grafo há pelo menos um ciclo estabelecido, sendo o ciclo a apresentação de pares do conjunto de entradas ou saídas dos dados no processo de aprendizagem da rede.

Para Côrtes *et al.* (2016), redes neurais binárias são estruturadas por classes com funções de leitura de entrada de dados, transformando os arquivos em sequências binárias para treinamento da rede neural artificial, transformando a sentença em uma sequência lógica binária para o reconhecimento e interpretação da saída binária da rede neural.

As redes intervalares, por outro lado, aceitam entrada de qualquer valor numérico de forma contínua no treinamento, podendo ser citados como exemplos os modelos de Backpropagation e Kohonen (SILVA *et al.*, 2018).

De acordo com Carvalho, (2018), as redes classificadas como competitivas têm o aprendizado não supervisionado, ou seja, a mesma não procura solução ótima para gerar as respostas, mas apresenta uma solução que apresenta bons resultados para o conjunto de dados (FURTUOSO *et al.*, 2022).

Nessas redes os neurônios de saída competem entre si para tornarem-se ativos, onde apenas um neurônio é ativado em cada interação, tornando-se apropriado para fazer agrupamentos (PUC, 2016).

As redes neurais supervisionadas, normalmente feito pelo algoritmo de retropropagação, são as mais utilizadas como forma de aprendizado (SILVA *et al.*, 2018). Esse tipo de rede possuem uma espécie de um supervisor para determinar a resposta que a rede deverá obter.

Já as redes com aprendizado não supervisionado, não possuem supervisor, diferente da supervisionada, assim não exige indicativos de comportamento preestabelecido para a rede, em outras palavras, não é possível determinar as saídas desejadas de acordo com os dados.

De acordo com SILVA *et al.* (2018), um exemplo que pode ser dado para redes com aprendizado não supervisionado, são as redes neurais de Kohonen, onde é inserido as entradas, e então é interpretada os processos de ajuste de conexões como os resultados em um processo de auto-organização, sem interferência externa.

Existindo incontáveis aplicações nas quais pode ser utilizada as redes neurais artificiais, sendo as mais conhecidas e utilizadas os mapas auto-organizados (self-organizing maps) para avaliação de dados, podendo ser combinado com outras técnicas como de agrupamento como dendrograma, índice de db e coeficiente de k-means.

2.4 Técnicas de agrupamento de dados

As técnicas de agrupamento de dados são metodologias estatísticas poderosas, principalmente porque são capazes de agrupar grupos similares e avaliar interações, mesmo quando a quantidade de dados é grande e ocorrem aleatoriamente. Quando usada mais de uma técnica de agrupamento em um conjunto de dados, pode trazer informações valiosas.

Dentro de uma propriedade rural ou via de circulação, as causas de acidentes podem mudar, podendo ocorrer em função das condições do terreno, condições das máquinas, tipo de equipamento, capacidade e experiência do operador, desrespeito às normas de segurança, condição climática e etc. (BELLOCHIO *et al.*, (2018).

Do ponto de vista estatístico, tamanha dinâmica e aleatoriedade, não pode ser só avaliada por meios tradicionais como teste de média ou estatística descritiva, pois pode não refletir a natureza dos dados e não gerar uma resposta satisfatória, condizente com a natureza dos dados.

O uso de técnicas computacionais, como as redes neurais artificiais (RNA), dendrograma, índice de db e coeficiente de k-means usadas para agrupar dados, no entanto, apresentam-se como alternativa viável por conseguir agrupar as classes mais frequentes e

identificar suas interações.

Para Comberti *et al.* (2018), mapas auto-organizados (SOM) combinado com coeficiente de k-means, são uma alternativa viável ao uso da análise estatística convencional, pois são técnicas de mineração de dados muito poderosa, quando associadas, para encontrar grupos ou padrões até então imperceptíveis em um conjunto de dados.

2.4.1 Mapas auto-organizados

As avaliações estatísticas tradicionais de dados que não são numéricos, com os dados de acidentes com máquinas agrícolas, trazem muitas dificuldades para análise e requer muitas suposições e muitos testes sobre a distribuição dos dados avaliados (COMBERTI *et al.*, 2018).

As técnicas de redes neurais artificiais, como os mapas auto-organizados, permitem extrair informações de um banco de dados com muitas informações, variáveis com características contínuas e também categóricas, obtendo padrões entre elementos de entrada e um de interesse, permitindo extrair informações e prever resultados (COSENZA *et al.*, 2017).

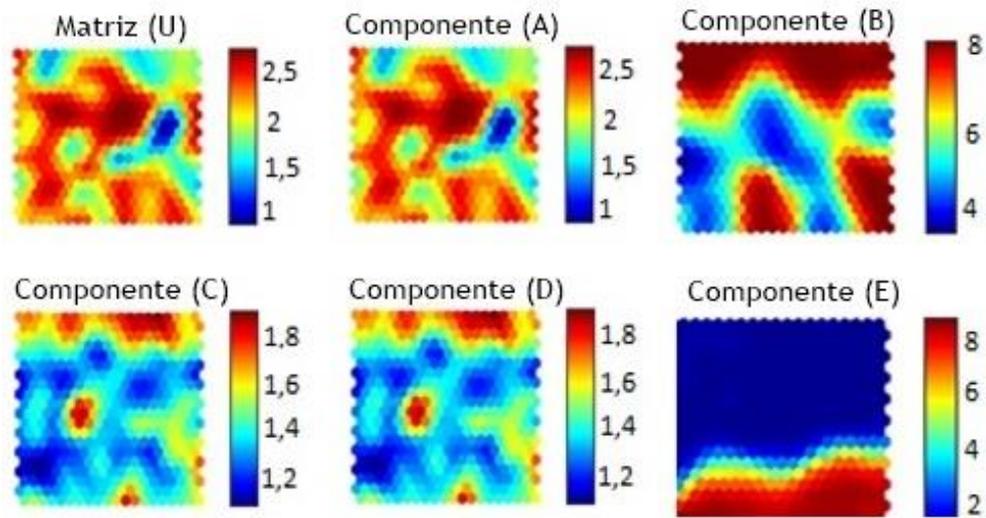
De acordo com Silva *et al.* (2018) e Carvalho *et al.*, (2016), dentro deste sistema, os sinais de entrada são fornecidos para outros neurônios como parâmetros iniciais, sendo variáveis de processadores interligados, operando em paralelo para executar uma função com seus códigos previamente estabelecidos.

De acordo com Claro *et al.* (2018), as redes neurais possuem modelos diferentes, nas quais a diferença em cada modelo é estabelecida através de características básicas de cada uma, como o tipo de entrada (binário e intervalar), conexão (forma de alimentação à frente, retroalimentação e forma de alimentação competitiva) e o tipo de aprendizado (aprendizado supervisionado, auto aprendizado ou aprendizado não supervisionado da rede).

De acordo com Druta *et al.* (2021), em um treinamento de rede neural auto-organizável, os neurônios competem entre si nas camadas para permanecer ativos, neurônio vencedor, em outras palavras, neurônio com maior atividade no processo de aprendizado.

Freire *et al.* (2022), reforça que o resultado como resposta ao processamento dos dados é um mapa com os agrupamentos desejados (FIGURA 6), onde o pesquisador pode tirar ou não as respostas de interesse do conjunto de dados do objeto avaliado.

Figura 6 - Exemplo de resultado de um treinamento de uma rede neural por mapas auto-organizados



Fonte: Elaborado pelo Autor.

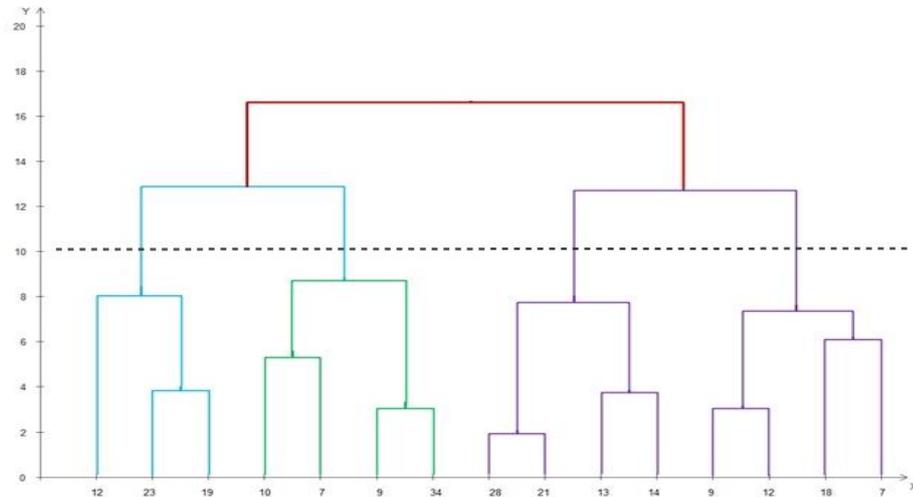
Uso de técnicas computacionais como os mapas auto-organizados é uma alternativa válida, podendo ser combinada com outras técnicas de agrupamentos; dendrograma e coeficiente de k-means para agrupar dados e avaliar similaridades ou mesmo interação nos grupos mais frequentes em um conjunto de dados (GOVENDER E SIVAKUMAR, 2020).

2.4.2 Dendrograma

O dendrograma como técnica de agrupamento, reúne objetos semelhantes em um conjunto de dados de entrada, essa semelhança é encontrada pela distância entre pares de objetos, quando dados com menor distância entre eles são encontrados, os mesmos são colocados em grupos semelhantes (ALBUQUERQUE *et al.*, 2021).

De acordo com Freire *et al.* (2022), seu resultado pode ser apresentado em um dendrograma, conforme mapa apresentado na Figura 7, que mostra um diagrama com a relação hierárquicas entre os objetos avaliados.

Figura 7 - Esquema de um dendrograma mostrando a relação hierárquicas entre os objetos avaliados



Fonte: Elaborado pelo Autor.

Para medir o coeficiente de distância, podem ser usadas várias metodologias existentes, no entanto a distância euclidiana é a mais aplicada (YOKOMIZO *et al.*, 2017). O dendrograma é uma metodologia com muitas aplicações e também pode ser combinada com outras técnicas de agrupamentos.

Martins *et al.* (2022), fazendo a caracterização e agrupamento das etnovariedades de mandioca, do Norte do Mato Grosso, mediante caracteres dos frutos usou essa técnica de agrupamento para alcançar seu objetivo, mostrando a versatilidade dessa metodologia para as mais diversas áreas do conhecimento.

Rodrigues *at al.* (2021), fazendo agrupamento em dados de qualidade da água de uma lagoa localizada no Sul do Rio Grande do Sul, também usou essa metodologia, mostrando sua eficiência para avaliar grupos similares.

Yokomizo *et al.* (2021), mostrou a eficiência dessa metodologia, estudando a estabilidade e adaptabilidade pelo uso combinado de dendrograma e AMMI em progênies de açaizeiro, mostrando que o dendrograma pode ser combinado com facilidade com outras metodologias, principalmente computacionais.

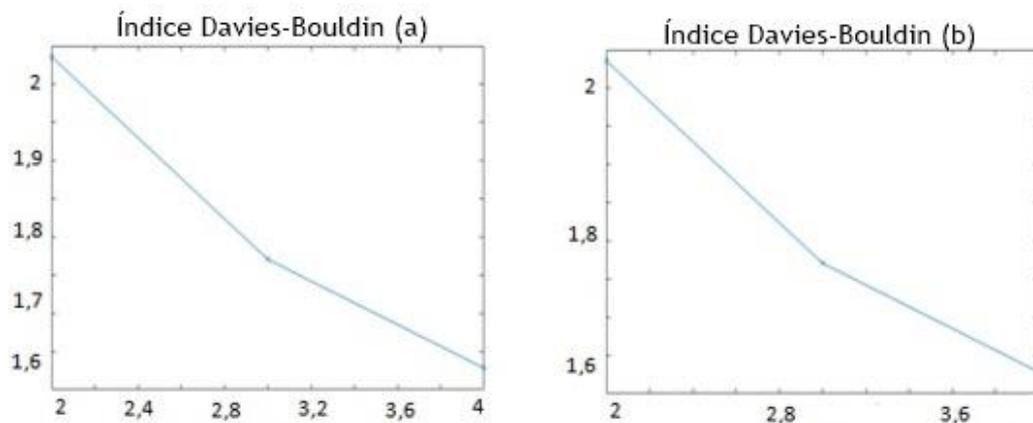
Macedo *et al.* (2019), também usou técnicas de agrupamento como o dendrograma, coeficiente de k-means e rede neural em acidentes com máquinas agrícolas em rodovias nas região Sul para agrupar os dados similares.

2.4.3 Índice de Davies-Bouldin (db)

De acordo com Ashari *et al.* (2022), Índice de Davies-Bouldin (db) analisa a formação dos agrupamentos formados pelas técnicas utilizadas. Nesse tipo de teste, quanto menor o valor do índice obtido, melhor o resultado, mostrando grandes distâncias intergrupos e baixas mediadas de dispersão intergrupos (GODOIS, 2018).

Septiani *et al.* (2022), reforça também que o índice de Davies-Bouldin (db) serve para que o pesquisador possa checar se os agrupamentos estão bem determinados e bem compactados e que quanto mais próximo de zero, melhor os agrupamentos dos dados avaliados. Nesse tipo de avaliação, o resultado geralmente é apresentado graficamente, conforme mostrado na Figura 8.

Figura 8 - Esquema da apresentação gráfica do Índice de Davies-Bouldin (db), usado para validação dos agrupamentos avaliados



Fonte: Elaborado pelo Autor.

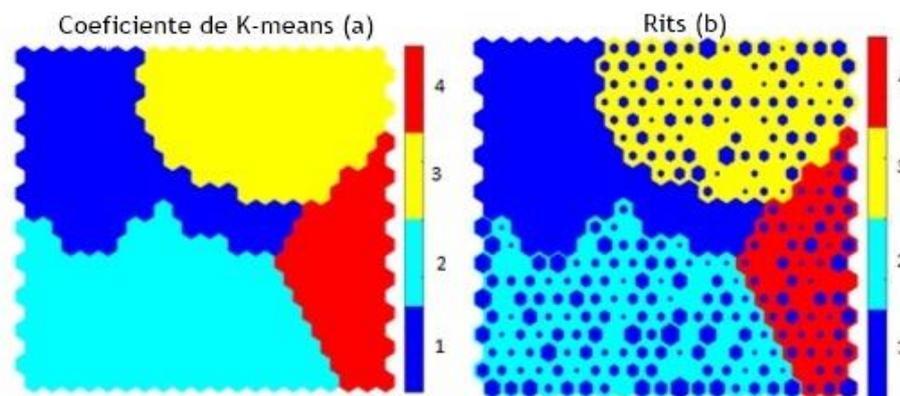
Ramadhani *et al.* (2022), fazendo comparação de algoritmos K-Means e K-Medoids em texto para classificação, baseada no índice Davies-Bouldin (db), mostrou que essa metodologia tem um desempenho satisfatório, mesmo quando os dados são aleatórios e não dizem nada quando não organizados em grupos.

Macedo *et al.* (2019), fazendo uso combinado de técnicas de agrupamento índice de davies-bouldin (db), dendrograma, mapas auto-organizados e coeficiente de k-means para avaliar sinistros com máquinas agrícolas nas rodovias federais em São Paulo, mostrando a eficiência dos métodos.

2.4. 4 Coeficiente de k-means

O método de agrupamento por coeficiente de k-means busca padrões entre os objetos de estudo, agrupando os mesmos pelo seu grau de semelhança, formando os grupos conforme são encontradas similaridades que permitam a formação de agrupamentos (RAMADHANI, 2022). A vantagem desse método é sua capacidade de delimitar os grupos com clareza, com limites bem delimitado (FIGURA 9).

Figura 9 - Esquema de um mapa de apresentação do coeficiente de k-mean com limites definidos em cores distintas



Fonte: Elaborado pelo Autor.

Pelo coeficiente de k-mean, as representações dos grupos são realizadas pelas médias numéricas, centroides de todos os objetos que compõe os agrupamentos formados e objeto de avaliação (AGRAMONTE E MALPARTIDA, 2021).

Orisa (2022), avaliando a otimização de cluster no algoritmo K-Means, também afirma que há várias coisas que precisam ser consideradas no processamento de dados, prestar atenção principalmente em como os dados são processados, selecionados e limpo de inconsistentes.

Saputri *et al.* (2022), aplicando o método de agrupamento K-Means para agrupar as necessidades de água limpa nas províncias da Indonésia com base em necessidades baixas, médias e altas usando, foi bem sucedida e fácil de implementar.

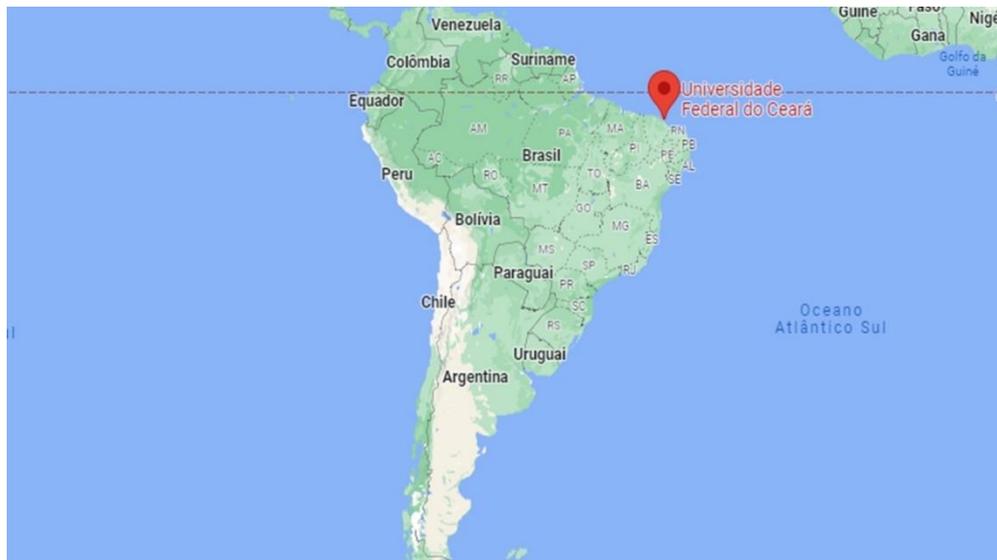
Marcedo (2018), fazendo uso de técnicas de agrupamento e rede neural em sinistros com máquinas agrícolas nas rodovias federais, também fez uso do Coeficiente de k-means para melhorar seus resultados, sendo possível separar os grupos com precisão.

3 MATERIAL E MÉTODOS

3.1 Local da pesquisa

O trabalho foi elaborado no Laboratório de Investigação de Acidentes com Máquinas Agrícolas (LIMA), vinculado ao Departamento de Engenharia Agrícola (DENA) da Universidade Federal do Ceará (UFC), a qual é geograficamente localizada no município de Fortaleza no estado do Ceará, *latitude: 3° 44' 44.682" S longitude: 38° 34' 55.632" W* (FIGURA 10).

Figura 10 - Universidade Federal do Ceará (UFC), localizada no município de Fortaleza no estado do Ceará



Fonte: Elaborado pelo Autor.

3.2 Obtenção dos dados

Os dados foram obtidos de uma base de dados do LIMA, com informações oriundas de notícias de acidentes com tratores vinculados à internet em todo o território nacional. Esta base de dados foi atualizada mensalmente, sendo constituída de uma quantidade robusta de informações coletadas desde 2013 a 2022, totalizando 1765 acidentes.

Para isso, foi utilizado o Google alerta, configurado com palavras chaves específicas para maior abrangência das buscas, tais como: acidentes envolvendo tratores, acidente fatal com trator, colisão com tratores, morte com máquinas agrícolas, acidentes com

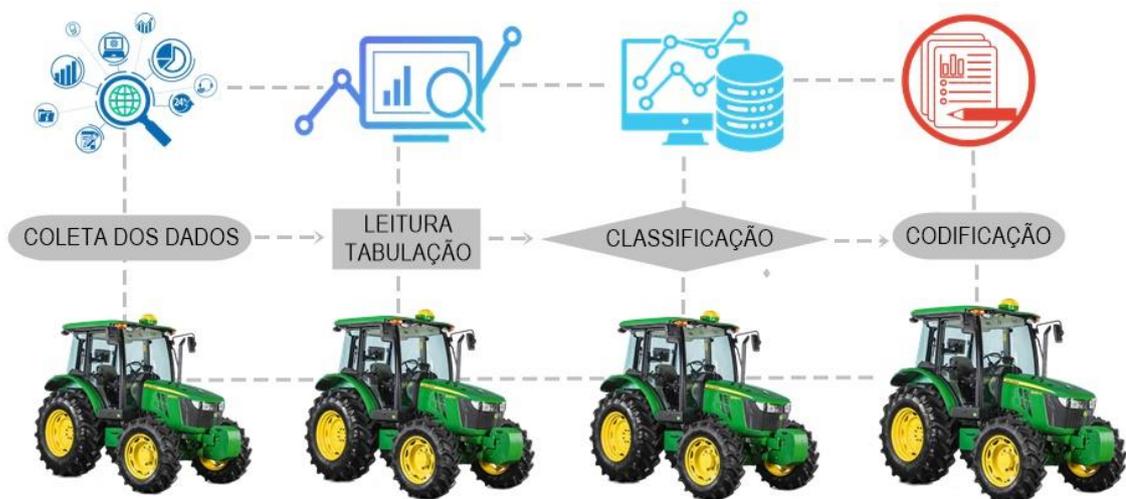
máquinas agrícolas em propriedades rurais e etc.

3.3 Processamento dos dados obtidos

Para que os dados de entrada pudessem ser processados pelos neurônios gerando mapas no software, preservando a relações de proximidade entre eles, as variáveis qualitativas foram transformadas em quantitativas, em que para cada classe foi atribuído um valor de acordo com a quantidade de classe, levando-se em consideração o grau de aproximação das classes.

Assim, cada indicador foi separado em classes e cada classe foi codificada com um número para facilitar a análise estatística. Os dados foram separados nos indicadores região de ocorrência, período do acidente, quantidade de vítima, local do acidente, tipo de acidente, causa do acidente, faixa etária do operador e tipo de implemento. O fluxograma abaixo exemplifica o processo de coleta, tabulação, classificação e codificação dos dados de acidentes com máquinas agrícolas (FIGURA 11).

Figura 11 - Fluxograma da coleta, tabulação, classificação e codificação dos dados de acidentes com máquinas agrícolas antes do treinamento da rede



Fonte: Elaborado pelo Autor.

3.3.1 Classificação das regiões de ocorrência

As regiões foram classificadas como: região Sul (Paraná, Santa Catarina e Rio Grande do Sul), Região Sudeste (Espírito Santo, Minas Gerais, Rio de Janeiro e São Paulo),

Região Centro Oeste (Goiás, Mato Grosso, Mato Grosso do Sul e o Distrito Federal), Região Nordeste (Maranhão, Piauí, Ceará, Rio Grande do Norte, Paraíba, Pernambuco e Sergipe), Região Norte (Amazonas, Roraima, Amapá, Pará, Tocantins, Rondônia e Acre) e não informado (TABELA 1).

Tabela 1 - Classificação e codificação de acordo com a região de ocorrência dos acidentes com máquinas agrícolas

Classe	Região de ocorrência					
	Região Sul	Região Sudeste	Região Oeste	Região nordeste	Região Norte	Não inf.
Código	1	2	3	4	5	6

Fonte: Elaborado pelo Autor.

3.3.2 Classificação e codificação do indicador quantidade de vítimas

O indicador de quantidade de vítimas, que se referem ao número de feridos ou vítimas fatais, envolvidas na ocorrência, foram classificadas em: sem vítima (quando não tem vítimas com ferimentos envolvidas); vítimas feridas (quando tem uma ou mais vítimas com ferimentos envolvidas) e vítimas fatais (quando tem um ou mais óbitos). quando a quantidade de vítimas ou óbitos envolvidos na ocorrência não foi informada, recebeu a denominação de não informado (TABELA 2).

Tabela 2 - Classificação e codificação dos acidentes de acordo com a quantidades de vítimas

Classe	Quantidade de vítima			
	Sem Vítimas	Vítima Feridas	Vítima Fatais	Não informado
Código	1	2	3	4

Fonte: Elaborado pelo Autor.

3.3.3 Classificação e codificação do indicador local do acidente

O indicador, local do acidente, refere-se à classificação do local em que a máquina agrícola se encontrava no momento do acidente, esse indicador serviu de parâmetro para mostrar a influência do local da ocorrência para que o acidente tenha acontecido ou não. No que diz respeito esse indicador temos as seguintes classificações: propriedade (quando o acidente ocorre na zona rural), vias públicas (quando o acidente ocorre dentro da cidade em vias públicas ou rodovias) e não informado (TABELA 3).

Tabela 3 - Classificação e codificação dos acidentes de acordo com o indicador local do acidente

Classe	Propriedade	Local do acidente	
		Via Pública	Não Informado
Código	1	2	3

Fonte: Elaborado pelo Autor.

3.3.4 Classificação e codificação do indicador tipo de acidente

O tipo de acidente foi classificado como aprisionamento de membros (ocorre quando um membro de uma pessoa fica preso no trator ou implemento), perda de membros (ocorre quando um membro de uma pessoa é removido pela máquina ou implemento), colisão (quando a frente da máquina abalroa com a frente de outro veículo na via), atropelamento (ocorrências onde tratores em movimento causaram lesões em pessoas ou animais), capotamento (ocorrência quando o trator gira em torno de si mesmo, tocando o solo com o teto em qualquer momento), queda do trator (pessoas caem do veículo), outro tipo de acidente (quando o acidente não se enquadra nesta classificação) e não informado (TABELA 4).

Tabela 4 - Classificação e codificação dos acidentes de acordo com o indicador tipo de acidente

Classe	Perda. Membros	Tipo de acidente		
		Aprisionamento membros	Colisão	Atropelamento
Código	1	2	3	4
Classe	Capotamento	Queda do trator	Outros	Não Informado
Código	5	6	7	8

Fonte: Elaborado pelo Autor.

3.3.5 Classificação e codificação do indicador causas de acidentes

As causas dos acidentes foram as situações ou condição que levaram a ocorrência do acidente, sendo classificadas como: irregularidade do terreno (quando o acidente ocorrer devido as condições do terreno), tomada de potência (causado pelo acionamento indevido do eixo cardan, resultando em lesões em pessoas ou perda de controle da máquina), velocidade incompatível com a via (velocidade acima ou abaixo da máxima ou mínima permitida da via ou operação), falta de atenção (ocorre pela falta de atenção por diferentes razões na condução da máquina, em via ou operações agrícolas), dormir ao volante (motorista ou operador

adormece no volante na operação com máquinas), embriaguez (um dos envolvidos estava sobre efeito de algum entorpecente ou bebida alcoólica), desobediência à sinalização (desrespeito a sinalização vertical e ou a horizontal), defeito mecânico (falha mecânica de algum dos veículos envolvidos ou equipamento acoplado), outras causas de acidentes (quando o acidente não se enquadra em nenhuma das classificações listadas) e não informada (TABELA 5).

Tabela 5 - Classificação e codificação dos acidentes de acordo com o indicador causas dos acidentes

Causa do acidente					
Classe	Irregularidade do terreno	Tomada de potência	Velocidade incompatível	Falta de atenção	Dormir ao volante
Código	1	2	3	4	5
Classe	Embriaguez	Desobediência à sinalização	Defeito mecânico	Outros	Não Informado
Código	6	7	8	9	10

Fonte: Elaborado pelo Autor.

3.3.6 Classificação e codificação do indicador faixa etária do operador

O indicador, faixa etária do operador, refere-se à idade do condutor envolvido no acidente, sendo classificado como: menos de 10 anos, de 11 a 17, de 18 a 30, de 31 a 40, de 41 a 50, de 51 a 60, de 61 a 70, mais de 71 anos e não informado. Esse indicador é importante porquê reflete as limitações e vantagens impostas pela idade do condutor (TABELA 6).

Tabela 6 - Classificação e codificação dos acidentes de acordo com o indicador faixa etária do operador

Faixa etária do operador					
Classe	Menos de 10 anos	De 11 a 17 anos	De 18 a 30 anos	De 31 a 40 anos	De 41 a 50 anos
Código	1	2	3	4	5
Classe	De 51 a 60 anos	De 61 a 70 anos	Acima de 71 anos	Não informado	
Código	6	7	8	9	

Fonte: Elaborado pelo Autor.

3.3.7 Classificação e codificação do indicador tipo de implemento

O tipo de equipamento agrícola tracionado pelo trator pode ser um fator colaborativo para ocorrência do sinistro, assim, esse parâmetro foi considerado como um

indicativo, sendo eles: arado, grade, enxada rotativa, pulverizador, semeadora, colhedora, carreta, outros implementos, trator e não informado (TABELA 7).

Tabela 7 - Classificação e codificação dos acidentes de acordo com o indicador tipo de implemento acoplado

Classe	Tipo de implemento				
	Trator	Arado	Grade	Enxada rotativa	Pulverizador
Código	1	2	3	4	5
Classe	Semeadora	Colhedora	Carreta	Outros implementos	Não informado
Código	6	7	8	9	10

Fonte: Elaborado pelo Autor.

3.3.8 Classificação e codificação do indicador período do acidente

Os períodos de ocorrência dos acidentes foram classificados em madrugada (00:00 às 05:59), manhã (06:00 às 11:59), tarde (12:00 às 17:59) e noite (18:00 às 23:59) e não informado. A classificação do período de ocorrência é muito importante, porque reflete as distintas condições do operador durante a jornada de trabalho dentro da propriedade ou trafegando pelas vias de circulação (TABELA 8).

Tabela 8 - Classificação e codificação dos acidentes de acordo com o indicador período do acidente

Classe	Período do acidente				
	Madrugada	Manhã	Tarde	Noite	Não inf.
Código	1	2	3	4	5

Fonte: Elaborado pelo Autor.

Após obtenção dos indicadores e classificação com atribuição dos códigos, conforme apresentado na tabela de resumo (FIGURA 9), foi possível formar uma matriz de dados no programa, inseridas através da função `som_read`, importando os arquivos do bloco de notas para o Matlab.

Tabela 9 - Resumo das classes codificadas referentes aos indicadores da região de ocorrência, período do acidente, quantidade de vítima, local do acidente, tipo de acidente, causa do acidente, faixa etária do operador e tipo de equipamento

Região de ocorrência						
Classe	Região Sul	Região Sudeste	Região Oeste	Região nordeste	Região Norte	Não inf.
Código	1	2	3	4	5	6
Período do acidente						
Classe	Madrugada	Manhã	Tarde	Noite	Não inf.	
Código	1	2	3	4	5	
Quantidade de vítima						
Classe	Sem Vítimas	Vítima Feridas	Vítima Fatais	Não informado		
Código	1	2	3	4		
Local do acidente						
Classe	Propriedade	Via Publica	Não Informado			
Código	1	2	3			
Tipo de acidente						
Classe	Perda. Membros	Aprisionamento membros	Colisão	Atropelamento	Capotamento	
Código	1	2	3	4	5	
Classe	Queda do trator	Outros	Não Informado			
Código	6	7	8			
Causa do acidente						
Classe	Irregularidade do terreno	Tomada de potência	Velocidade incompatível	Falta de atenção	Dormir ao volante	
Código	1	2	3	4	5	
Classe	Embriaguez	Desobediência à sinalização	Defeito mecânico	Outros	Não Informado	
Código	6	7	8	9	10	
Faixa etária do operador						
Classe	Menos de 10 anos	De 11 a 17 anos	De 18 a 30 anos	De 31 a 40 anos	De 41 a 50 anos	
Código	1	2	3	4	5	
Classe	De 51 a 60 anos	De 61 a 70 anos	Acima de 71 anos	Não informado		
Código	6	7	8	9		
Tipo de implemento						
Classe	Trator	Arado	Grade	Enxada rotativa	Pulverizador	
Código	1	2	3	4	5	
Classe	Semeadora	Colhedora	Carreta	Outros implementos	Não informado	
Código	6	7	8	9	10	

Fonte: Elaborado pelo Autor.

Logo, um acidente que ocorreu na região Sul, pela manhã, com vítimas fatais, em uma propriedade rural, com capotamento, devido à irregularidade no terreno, com operador com 20 anos de idade e puxando um arado, recebeu como vetor na entrada da matriz a linha de código: 1, 2, 3, 1, 5, 1, 3 e 2.

Para que o programa pudesse ler os dados no bloco de nota, os dados foram organizados com o número de variáveis a ser analisado na primeira linha, na segunda linha o

nome das variáveis estudadas, na terceira linha os dados foram colocados por colunas e na última coluna foi realizada a identificação dos neurônios em ordem numérica de 1 a 1765 (quantidade de acidentes avaliados) para facilitar a identificação e formação dos grupos pelo coeficiente k-means (FIGURA 12).

Figura 12 - Sequência do preenchimento do bloco de notas para importação dos dados para o software



#n	Região	Período	vítimas	Local	Tipo	Causa	Idade	Implemento	Identificação
3	4	1	3	7	6	9	1	1	
4	2	3	1	7	6	3	1	2	
2	4	3	1	7	4	6	4	3	
3	4	3	3	7	4	4	1	4	
3	1	3	2	2	4	5	8	5	
3	4	2	2	7	4	9	1	6	

Fonte: Elaborado pelo Autor.

Após essas etapas, os dados foram normalizados usando a função `som_normalize`, colocados em escala equivalente evitando erros, como amplitude muito grande entre os dados, assim, foi utilizado a ‘var’, com normalização ocorrendo com os valores entre 0 e 1 a partir dos valores das amostras fornecidas.

3.4 Avaliação dos dados

3.4.1 Treinamento das redes neurais

Depois de formar a matriz de dados, quatro configurações de rede foram treinadas individualmente (14x15, 15x15, 20x20 e 25 x25), a primeira configuração do treinamento da rede neural artificial foi realizada com base na equação geral para determinar o número ideal de neurônios da primeira rede (EQUAÇÃO 1).

$$N = 5\sqrt{A}$$

(1)

N = Número de neurônios;

A = Número de amostras.

Os demais parâmetros da rede foram gerados pela própria rede durante o aprendizado computacional, utilizada a função `som_make` do Toolbox que cria, inicializa e treina o mapa com parâmetros “default”, sendo obtidos os valores do algoritmo de treinamento, inicialização, topologia, formato de vizinhança, taxa de aprendizagem, número de épocas, raio de vizinhança inicial e raio final.

Todo processo de aprendizagem é definido por cinco fases bem definidas computacionalmente e consistem na inicialização, amostragem, casamento por similaridade, atualização e continuação.

Na inicialização, o algoritmo escolhe os valores ao acaso para os vetores de pesos iniciais $w_j(0)$, com restrições, para que os vetores de entrada sejam diferentes para $j = 1, 2, 3, \dots, l$, sendo l o número de neurônios na grade avaliada. O sistema também pode iniciar selecionando o vetor de peso pelos padrões de entrada aleatoriamente.

Na amostragem, o sistema tira do espaço amostral de entrada uma amostra x , que representa a ativação aplicada à grade avaliada e sua dimensão é igual a m . Assim, o sistema inicia a fase de casamento por similaridade, encontrando o neurônio vencedor $i(x)$ no tempo n , usando o método de similaridade de distância euclidiana (EQUAÇÃO 2):

$$i(x) = \underset{j}{\operatorname{arg\,min}} \quad \|x(n) - w_j\|, j = 1, 2, \dots, l \quad (2)$$

Após encontrar os neurônios vencedores, inicia-se a fase de atualização. Nessa fase de atualização é ajustado os pesos sinápticos de todos os neurônios, usando a equação de atualização (EQUAÇÃO 3), obtendo-se os melhores resultados com a alteração dinâmica da taxa de aprendizagem e função de vizinhança dos neurônios eleitos como vencedores.

$$w_{j,i(n)}(n+1) = w_{j,i(n)}(n) + n(n)h_{j,i(n)}(n)(x(n) - w_{j,i(n)}(n)) \quad (3)$$

Onde:

$n(n)$ = Parâmetro de taxa de aprendizagem;

$h_{j,i(n)}$ = Função de vizinhança centrada em torno do neurônio vencedor $i(x)$.

Por último, temos a fase de continuação, em que a amostragem, casamento por similaridade e atualização são repetidos pelo sistema de algoritmos até não se observar mais modificações no mapa final da rede treinada, fechando o processo de aprendizagem com o

ajuste dos pesos, seleção dos neurônios vencedores, cálculo da distância euclidiana e posição de cada amostra de entrada no mapa gerado após aprendizagem.

Como parâmetro para escolha da melhor configuração de rede foram usados os erros topográficos e os erros de quantização, que quanto mais próximo de zero, melhor (EQUAÇÕES 4 E 5). O dimensionamento de uma rede de mapas auto-organizáveis, é um método de tentativas e erros. Podem ser realizados vários treinamentos com diferentes considerações, onde a rede escolhida deve ter resolução suficientemente boa e precisão estatística para análises dos dados (KOHONEN, 2016).

$$Te = \frac{1}{n} \sum_{k=1}^n u(k_x)$$

(4)

Te = Erro topográfico;

n = Número total de padrões;

$u(xk) = 1$ caso o primeiro e o segundo neurônios vencedores não sejam adjacentes;

$u(xk) = 0$ caso o primeiro e o segundo neurônio são vizinhos.

$$Qe = \frac{\sum_{k=1}^n ||xk - \omega_{BMU}||}{n}$$

(5)

Onde:

Qe = Erro de quantização;

xk = Vetor de entrada;

ω_{BMU} = Vetor peso.

Após determinada a configuração mais adequada, a rede foi treinada novamente em um processo automático, conforme códigos de programação das funções de entrada do software e caixa de ferramenta Toolbox.

Assim, foram gerados os mapas com seus planos componentes e matriz unificada com a rotina de visualização `som_show` da caixa de ferramenta. Na matriz unificada, também foram inseridas as marcações de cores, rótulos, `hist` e frequência com as funções `som_autolabel`, `som_show_add` e comando `freq`.

Com o intuito de determinar de forma mais assertiva o número de grupos mais adequados para serem utilizados no coeficiente de k-means, foram utilizados o dendrograma e Índice de Davies-Bouldin para chegar a um número de grupos adequado.

3. 4. 2 Dendrograma

Para formação do dendrograma foi usado processo hierárquico aglomerativo com medidas de similaridade formando os grupos (EQUAÇÃO 6). Em cada etapa do agrupamento, os conglomerados que estavam mais parecidos foram combinados em um único grupo, conforme (SOBRINHO *et al.* 2019)

$$dx_1 = \left[\sum_{i=1}^p (x_{il} - x_{ik})^2 \right]^{\frac{1}{2}} \quad (6)$$

Onde:

$d(X_l, X_k)$ = distância entre os dois elementos X_l e X_k , com $l \neq k$;

X_{il} = representa o valor observado da variável i medida no elemento l ;

X_{ik} = representa o valor observado da variável i medida no elemento k .

Assim como para a matriz U, para geração do dendrograma foram utilizadas as funções `som_read`, `som_normalize` e `som_make`, no entanto, para criar uma ligação hierárquica das unidades dos mapas avaliados, foi utilizada a função `som_linkage` também.

E por último, foi utilizada a função `som_dendrogram` para visualização da árvore de classes, gerada na função `som_linkage` no primeiro momento de criação da ligação hierárquica das unidades dos mapas.

No dendrograma dos dados avaliados, para determinar com precisão a altura de corte e encontrar o número de grupos ideais, foi usado o valor central da zona de transição da matriz unificada do treinamento da rede.

3. 4. 3 Índice de Devies-Bouldin (DB)

O índice DB foi usado conforme Equação 7 (PETROVIC, 2006), esse método avalia agrupamentos através da identificação de anomalias, sendo analisada a ligação do centroide como distância entre clusters, avaliado a relação inter e intra clusters, sendo selecionadas medidas compatíveis com o algoritmo k-means.

$$DB = \frac{1}{k} \sum_{i=1}^k \max_{i \neq j} \left\{ \frac{\Delta(c_i) + \Delta(c_j)}{\delta(c_i c_j)} \right\} \quad (7)$$

Onde:

DB = índice de Devies-Bouldin;

K = número de clusters;

$\Delta(C_i)$ = distância intra-clusters;

$\delta(C_i, C_j)$ = distância inter-clusters;

$\Delta(C_j)$ = diâmetro do centroide.

O índice de Devies-Bouldin foi calculado usando como número de agrupamentos máximos, o número de grupos obtidos pelo dendrograma. Na caixa de ferramenta somtoolbox foi criada uma ligação hierárquica das unidades dos mapas com a função som_linkage, sendo possível gerar o dendrograma e índice de Devies-Bouldin a partir das funções som_dendrogram e som_db na caixa de ferramenta somtoolbox com a sua visualização.

3. 4. 4 Coeficiente k-means

Após determinar o número de agrupamentos, foi utilizado o coeficiente k-means para separar o conjunto de dados em K-classes com semelhanças de acordo com medidas de similaridade, separando os k vetores aleatoriamente, calculando as distâncias euclidianas dos centroides e os padrões de entrada. Posteriormente, foi associando cada vetor ao centroide mais similar do conjunto de dados (PALAMARA, PIGLIONE e PICCININI, 2014). Depois de dividir os padrões de entrada, o sistema calculou os novos centroides, formando os grupos pelo seu grau de similaridade. (EQUAÇÃO 8).

$$c_i = \frac{1}{m_i} \sum_{j=1}^{m_i} x_{ji}$$

(8)

Onde:

c_i = centroide do cluster C_i ;

m_i = número de dados x_j reunidos no cluster C_i .

Com os grupos obtidos pelo índice de Devies-Bouldin, foi usado o coeficiente de k-means para gerar e visualizar esses grupos no mapa com marcações de cores, rótulos, hist e frequência para separação e tabulação dos dados referentes a cada grupo e posterior visualização projetada na matriz unificada e obtenção das frequências de classes. Nos mapas dos coeficientes de k-means também foram inseridas as marcações de cores, rótulos, hist e

frequência com as funções `som_autolabel`, `som_show_add` e comando `freq`.

Para treinamento e simulação da rede neural artificial (rede SOM), após formação da matriz de dados com classes de indicadores codificadas, foi utilizado o software MATLAB 2016a, com a caixa de ferramentas `somtoolbox`, responsável pelo treinamento da rede neural e simulação no ambiente computacional e visualização dos mapas.

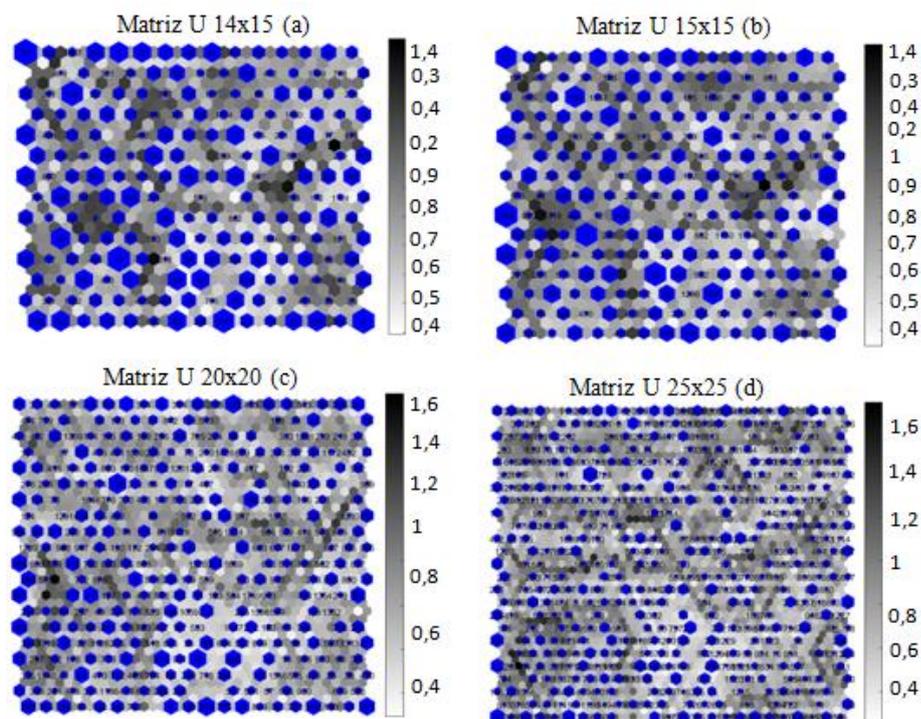
4 RESULTADOS E DISCUSSÃO

Diferentes configurações de redes foram treinadas inicialmente a fim de encontrar a quantidade de neurônio capaz de representar o conjunto de dados avaliados e extrair informações a partir de uma apresentação gráfica com nitidez.

Esse procedimento é importante porque permite ao treinador avaliar previamente qual a quantidade ideal de neurônios para formação de grupos sem superdimensionamento da rede, permitindo visualizar os grupos formados.

A primeira rede treinada foi com uma configuração de 14x15 (FIGURA 13) totalizando 210 neurônios avaliados, com um erro de quantização e erro topográfico de 1,49 e 0,9 respectivamente conforme treinamento.

Figura 13 - Matriz unificada 14x15 (a), 15x15 (b) 20x20 (c) e 25x25 (d) com rótulos e hist inseridos na fase inicial de avaliação



Fonte: Elaborado pelo autor.

Essa configuração inicial foi determinada com base na equação geral para determinação do tamanho da rede neural, determinando um tamanho mínimo para rede treinada capaz de gerar nitidez para uma avaliação visual.

Mesmo com o mapa resultante, apresenta resolução capaz de identificar pelo menos 3 agrupamentos, representados pelas áreas mais claras do mapa com grupos similares e áreas mais escuras com não similares ou áreas de bordas, foram treinadas mais 3 redes neurais

artificiais.

O treinamento de mais 3 configurações de redes 15x15, 20x20 e 25x25 foi realizado com o propósito de reduzir o erro de quantização e melhorar a resolução do mapa e identificar melhor os agrupamentos, no entanto, o aumento do número de neurônios não apresentou um ganho significativo na redução do erro de quantização e conseqüentemente resolução do mapa (TABELA 10).

De acordo com Kohonen (2016), o dimensionamento de uma rede de mapas auto-organizáveis, é método de muitas tentativas e erros. Podem ser realizados vários treinamentos com diferentes considerações desejadas, em que a rede escolhida deve ter resolução suficiente para ser considerada boa e com precisão aceitável, para análise dos dados com segurança do resultado gerado.

Tabela 10 - Erro de quantização e topográfico de acordo com o tamanho das redes treinadas no processo de aprendizagem

TAMANHO DA REDE		PARÂMETROS	
Dimensão	Neurônios	Erro de quantização	Erro topográfico
14x15	210	1,49	0,09
15x15	225	1,47	0,09
20x20	400	1,27	0,07
25x25	625	1,22	0,08

Fonte: Elaborado pelo autor.

Para validação, duas métricas podem ser utilizadas, o erro de quantização, verifica ajuste dos vetores de entrada na rede e erro topográfico avalia capacidade do mapa em representar a topologia dos dados, ou seja, verifica se os vetores de entrada da rede estão bem ajustados (CARVALHO *et al.*, 2016).

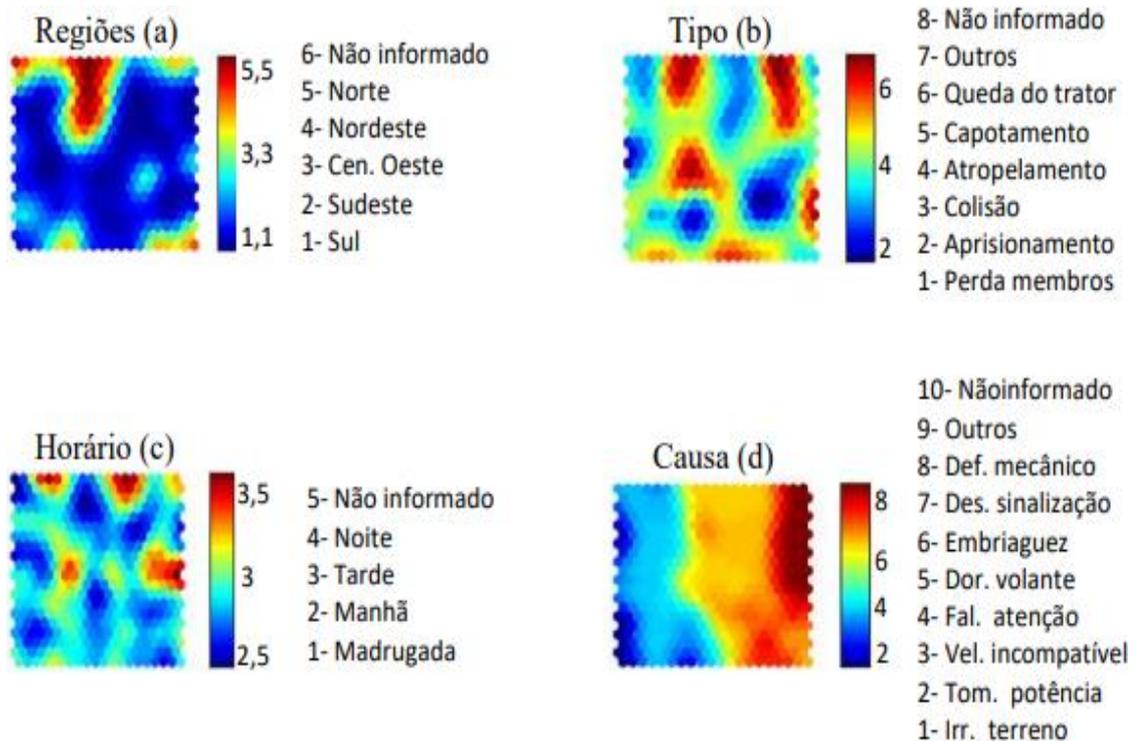
Para Macedo *et al.* (2018), em relação ao erro de quantização e erro topográfico, quanto mais próximos de zero forem os valores obtidos, maior é a resolução do mapa e representação dos dados. Dessa forma, podemos considerar que os valores obtidos são satisfatórios, quando próximos de zero.

Das redes treinadas, a configuração escolhida foi a 20x20 com 400 neurônios, pois o erro topográfico não diminuiu, e o erro de quantização da configuração 25x25 voltou a crescer e as configurações 14x15 e 15x15 não apresentaram variação expressiva nos erros de quantização e topográfico.

Na Figura 14 encontram-se os planos componentes dos acidentes com máquinas agrícolas em vias públicas e propriedades rurais para as regiões de ocorrência (a), tipo de

acidente (b), período da ocorrência (c) e causa do acidente (d), com suas respectivas classes utilizadas na avaliação.

Figura 14 - Planos componentes dos acidentes com máquinas agrícolas em vias públicas e propriedades rurais para as regiões de ocorrência (a), tipo de acidente (b), período da ocorrência (c) e causa do acidente (d)



Fonte: Elaborado pelo autor.

De acordo com Resta *et al.* (2018) é muito importante um estudo antecipado dos planos componentes da rede, isso porque através dos planos é possível a verificação da representação geral do mapa, ou seja, se as classes estudadas não afetam a análise geral, fornecendo uma análise detalhada do conjunto de dados.

Os agrupamentos nos planos componentes podem ser identificados pela paleta de cores e sua legenda de distância, que variam em função dos códigos utilizados para identificar as classes em cada indicador.

A primeira cor da paleta de cores com sua legenda de distância representa os agrupamentos formados, ou seja, os neurônios mais próximos. Já as cores e legendas centrais e de topo representam área de transição ou bordas.

Para as regiões de ocorrência, as classes mais representativas, com maior número de neurônios ativados, foram as regiões Sul e Sudeste, código 1 e 2, cor azul no mapa com a região Sul mais representativa. Esse resultado pode estar associado a um maior número de

máquinas e registro de acidentes nessa região, de acordo com o relatado por Anfavea (2022).

Para Sousa *et al.* (2022), os assistentes com máquinas agrícolas na região Sul podem ser justificados pelo maior número de máquinas e intensidade de fluxo, tanto no campo, como em vias públicas de circulação.

Observado os planos componentes referentes aos horários, as classes mais representativas com maior número de neurônios próximos, foram os horários da manhã e tarde, código 2 e 3, podendo estar associada ao número maior de máquinas no campo nesses horários, principalmente pela manhã, pelo fato de ser o início da jornada de trabalho em muitas propriedades rurais.

Resultado semelhante foi encontrado por Macedo *et al.* (2020), estudando os horários de acidente com máquinas agrícolas em rodovias federais, com o maior número de ocorrência no final da madrugada e início da manhã, colaborando significativamente com esse estudo.

Nos planos componentes referentes à tipo e causa de acidente, as classes com mais neurônios ativados foram, respectivamente, aprisionamento de membros e tomada de potência, código 2, cada uma em planos componentes diferentes, mais podendo ser apontadas como classes com alto grau de proximidade, tendo em vista que muitos dos acidentes com aprisionamento de membros acontecem na tomada de potência.

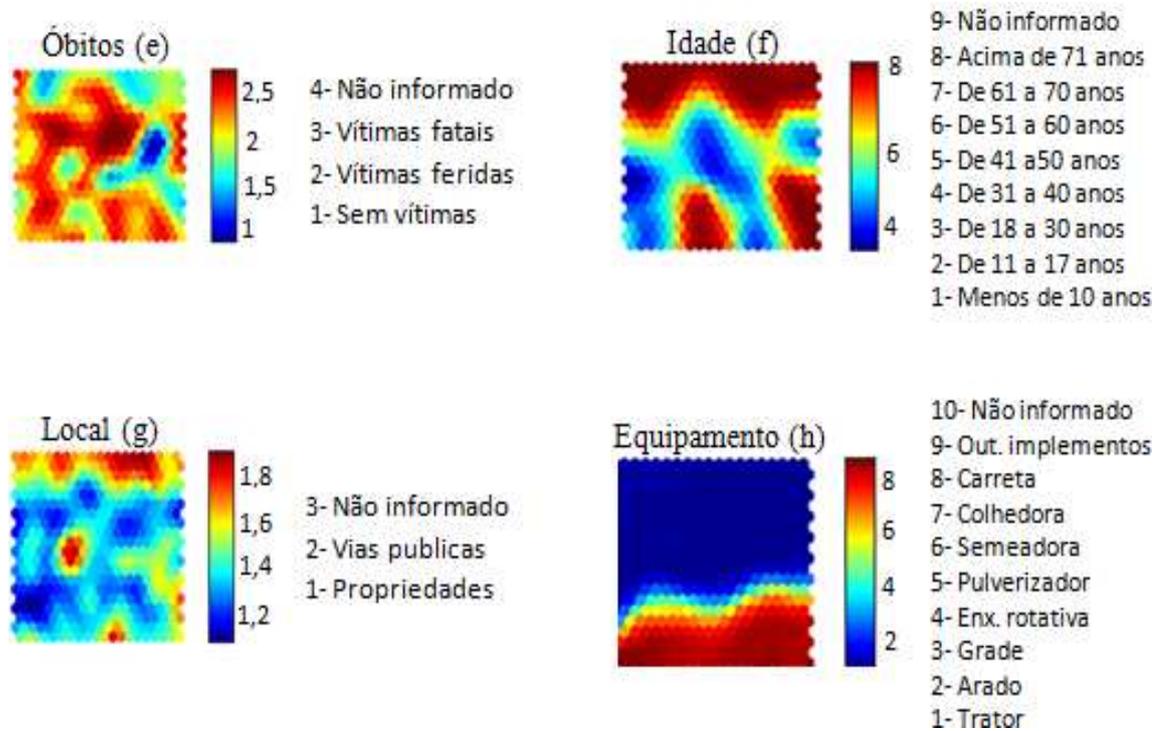
Em estudos realizados por Macedo *et al.* (2019), atropelamento e danos eventuais foram os tipos de acidentes mais relevantes, para a causa, defeito mecânico e desobediência à sinalização se sobressaiu nos planos componentes avaliados, no entanto os autores apenas estavam trabalhando com dados do estado de São Paulo e com acidentes ocorridos em rodovias federais.

Na Figura 15 encontram-se os planos componentes dos acidentes com máquinas agrícolas em vias públicas e propriedades rurais para quantidade de óbitos (e), faixa etária do operador (f), local da ocorrência (g) e tipo de equipamento (h).

Para quantidade de óbitos, a classe mais representativa com neurônios ativados, foi a classe sem vítimas, código 1. No entanto, formou um grupo muito pequeno. Esse resultado é muito importante e mostra que as máquinas agrícolas tem grande potencial para causar danos, resultando geralmente em ferimentos graves ou mesmo, óbito.

Em estudos realizados por Macedo *et al.* (2018), o resultado das análises dos planos componentes foi compatível com esse resultado, pois o grupo sem vítimas gerado na análise, também foi irrelevante.

Figura 15 - Planos componentes dos acidentes com máquinas agrícolas em vias públicas e propriedades rurais para quantidade de óbitos (e), faixa etária do operador (f), local da ocorrência (g) e tipo de equipamento (h)



Fonte: Elaborado pelo autor.

Yuan *et al.* (2017), estudando acidentes com máquinas agrícolas, puderam observar a maior parte das ocorrências de acidentes com vítimas fatais ocorrendo nas horas mais escuras das regiões estudadas.

Observado o plano componente referente aos locais das ocorrências, as classes com maior número de neurônios foi a propriedade rural e vias públicas, código 1 e 2, com valores de maior ativação próximos do código 1, mostrando que os acidentes ocorrem com uma frequência um pouco maior em propriedades rurais.

Para Santos *et al.* (2022), o Brasil é um dos maiores produtores agrícolas do mundo, no entanto, mesmo com adequação do trabalho no campo para a modernidade, passou a apresentar, apesar de poucas estatísticas, uma grande quantidade de acidentes nas propriedades rurais.

No plano componente referentes à idade do operador, a classe dominante com maior número de neurônios ativados foi na faixa etária de 31 a 40 anos, código 4. Resultado este, que pode estar associado ao fato de essa faixa etária ser a idade mais ativa dos operadores de máquinas agrícolas.

Trabalhadores rurais com idades acima de 50 anos, manifestaram maior resistência quando comparados aos mais jovens nas abordagens de segurança no trabalho, constatando que a escolaridade e a experiência de trabalho trazem maior conhecimento sobre esses aspectos (PEREIRA et al., 2020).

De acordo com o resultado obtido para o local do acidente e faixa etária do operador das máquinas agrícolas, um acidente pode ocorrer por vários motivos e precisa ser avaliado com profundidade e de forma detalhada.

Para Rondelli *et al.* (2018), só uma análise de circunstâncias que levaram aos sinistros acontecerem, pode estabelecer as medidas apropriadas para prevenção de acidentes com vítimas feridas ou até ocorrências de óbitos.

No plano componente tipos de equipamentos tracionados pelo trator, a classe que mais ativou neurônios na fase de treinamento foi o arado para preparo do solo, código 2, cor azul no mapa formando um grande grupo.

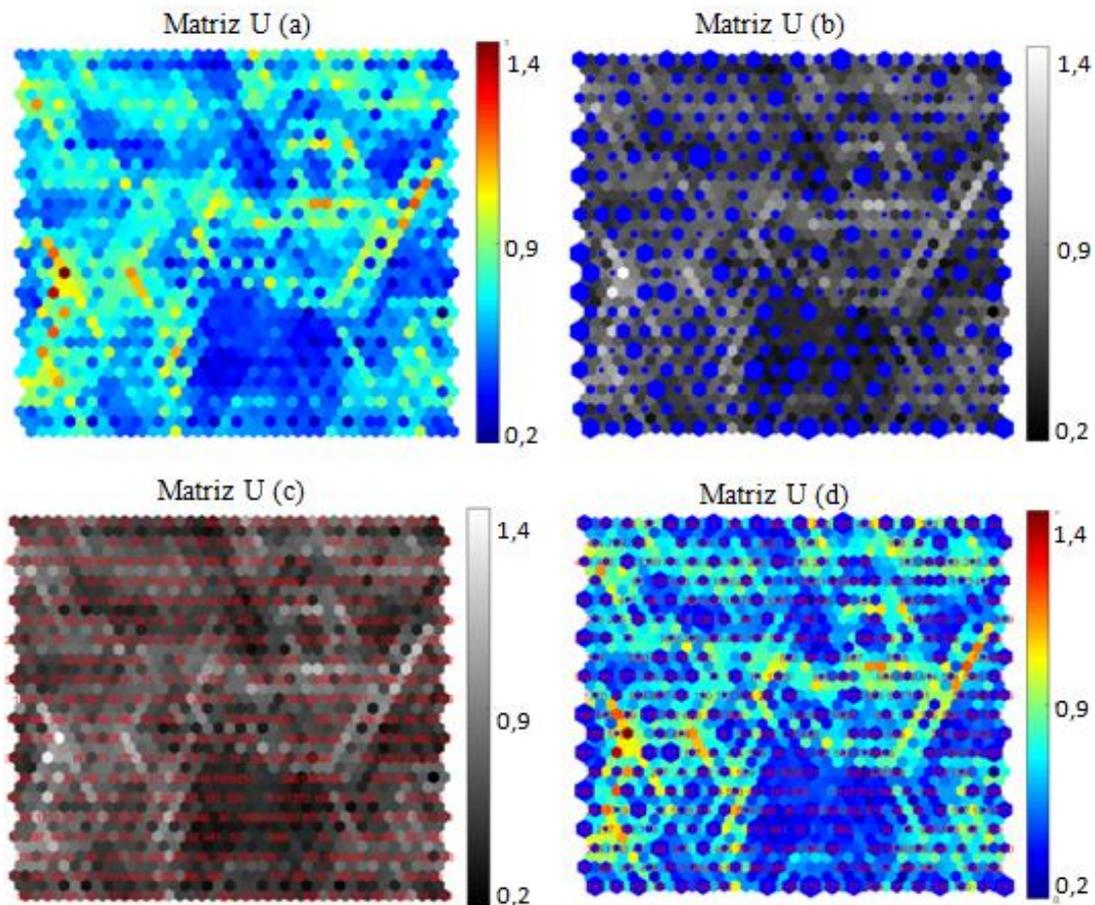
No primeiro momento, esse resultado pode parecer perturbador, tendo em vista o risco que outros equipamentos representam, no entanto, esse equipamento é muito comum em propriedades rurais, utilizado em preparos profundo de solo e condição da superfície mais difícil, o que pode contribuir para ocorrência de acidentes.

Antunes *et al.* (2018) afirma que o uso incorreto de máquinas agrícolas, em vias públicas ou propriedade rural, podem resultar em acidentes; e o trator é um dos equipamentos usados na agricultura que mais causam óbitos em decorrência de sinistros na atividade no campo.

Podemos observar ainda, do ponto de vista visual, que os planos componentes, tipo, horário e local do acidente são muito semelhantes, o que pode indicar uma correlação entre os atributos apresentados nas duas últimas figuras avaliadas. Pois as áreas onde os neurônios foram ativados como unidades próximas, formando agrupamentos, apresentaram padrões visuais parecidos.

Na Figura 16 podemos observar a matriz unificada colorida indicando os agrupamentos (a), matriz unificada com histos inseridos, a partir deles é possível determinar qual parte do mapa melhor representa os dados (b), matriz unificada preta e branca com rótulos (c), matriz U colorida com hist e rótulos (d).

Figura 16 - Matriz unificada colorida (a), matriz unificada com hist inseridos (b), matriz unificada preta e branca com rótulos (c), matriz unificada colorida com hist e rótulos (d)



Fonte: Elaborado pelo autor.

Para os dados de acidentes com máquinas agrícolas em vias públicas e propriedades rurais para configuração 20x20, podemos observar pelo menos 4 grupos bem distintos, com divisão ocorrendo nas linhas mais claras, pois os valores altos da legenda de distância (0,9 até 1,4) é que indicam a borda dos grupos; a cor preta e azul (0,2) representa os neurônios mais próximos, ou seja, os próprios agrupamentos formados.

Em uma matriz unificada, os neurônios de mesma coloração indicam uma proximidade maior entre o conjunto de dados, resultando em menor distância euclidiana entre os objetos, coloração distinta indicam uma menor proximidade e uma maior distância euclidiana entre os objetos avaliados (CARBONARI *et al.*, 2018).

A rede neural artificial de mapas auto-organizáveis aplicada em dados de acidentes permitiu encontrar padrões similares e fatores que favoreceram a ocorrência, sendo possível extrair informações importantes na prevenção para operadores de máquinas, elaboradores de projetos, gestão de risco e etc. (MOURA *et al.*, 2018).

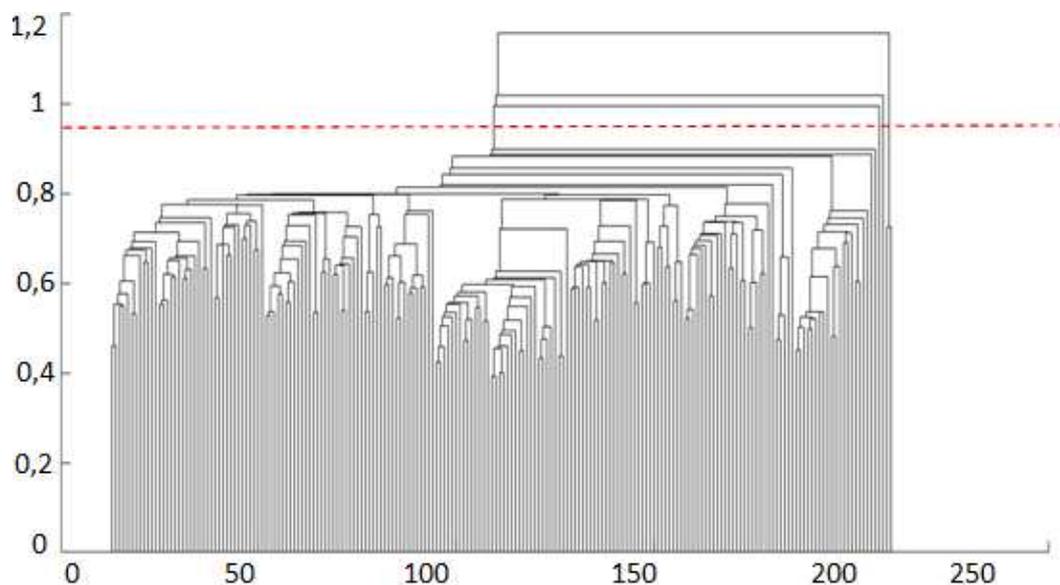
Para identificar o número exato de agrupamentos foram utilizados o dendrograma

e índice de Devies-Bouldin. No dendograma, para determinar adequadamente a altura certa de corte para definir os grupos que foram formados com esse método. Essa altura de corte foi realizada conforme o número de agrupamento desejado ou determinado, neste caso matriz unificada.

Mesmo que visualmente o número de agrupamentos não possa ser definido com clareza pela matriz unificada, eles podem ser obtidos através do valor referente à área de borda ou limite no mapa, ou seja, 0,9 é o valor da altura de corte. Assim, a reta feita na altura de corte utilizada interceptou o gráfico em 4 pontos mostrando 4 grupos (FIGURA 17).

Rodrigues *et al.* (2021), afirma em seu estudo que o dendograma é um tipo muito específico de diagrama ou forma de representação icônica que pode agrupar organizadamente determinados fatores ou variáveis. Destacando ainda em seu trabalho que a altura de corte também pode ser visual, considerando a homogeneidade e coerência dentro dos grupos obtidos.

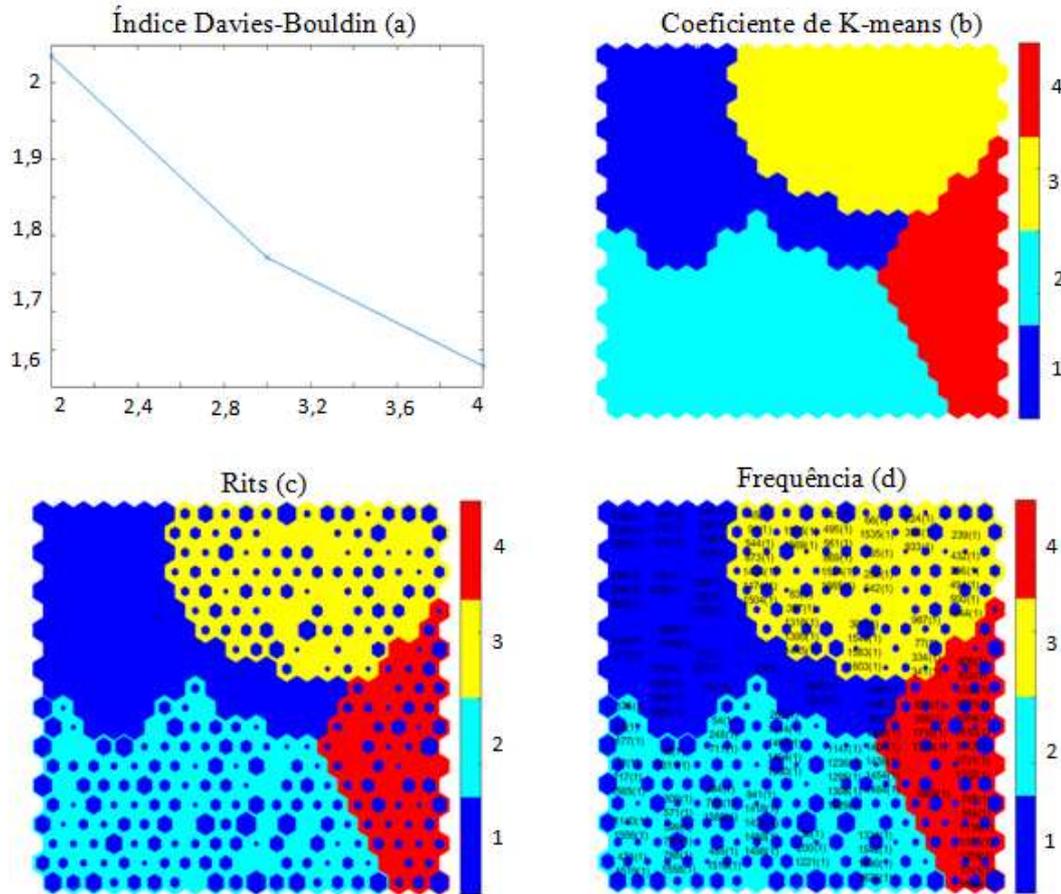
Figura 17 - Dendograma dos acidentes com tratores em vias públicas e propriedades rurais



Fonte: Elaborado pelo autor.

Depois dos grupos serem identificados, o índice de Devies-Bouldin também foi utilizado para chegar ao número ideal de grupos, que tomou como partida, 2 grupos e as possibilidades de agrupamento, podendo variar até 4. Obtendo-se $k=4$, menor valor que pode ser visto no gráfico na Figura 18. O valor de 4 agrupamento é o menor valor encontrado e que melhor representa os dados avaliados.

Figura 18 - Índice de Davies-Bouldin (a), coeficiente de k-means com as classes separadas em cores (b), hist inseridos no gráfico do coeficiente de k-means (c) e frequência das classes inseridas no gráfico do coeficiente de k-means (d)



Fonte: Elaborado pelo autor.

Macedo *et al.* (2019), usando de técnicas de agrupamento de dados e rede neural em acidentes com máquinas agrícolas nas rodovias federais em São Paulo, também encontrou um número de grupos compatível com o tamanho da rede treinada, aplicando a mesmas técnicas de agrupamento.

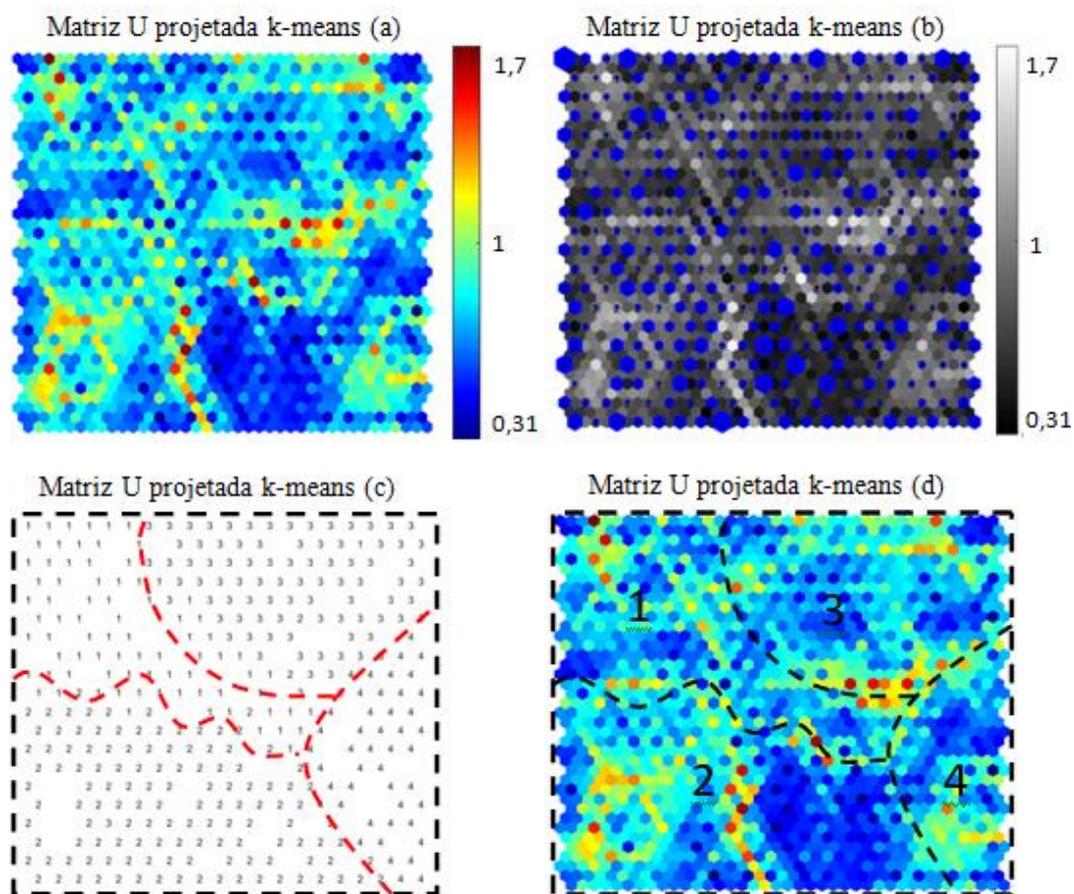
Considerando que o número de grupos é previamente estabelecido pelo usuário da rede neural artificial auto-organizável, a escolha do melhor número de grupos pode ser escolhida pelo índice de Davies-Bouldin. Também podemos determinar os grupos pelo índice de k-médias e os mapas auto-organizável existente (ARCOVERDE *et al.*, 2011).

Quando os agrupamentos, referentes aos acidentes com máquinas agrícolas em vias públicas e propriedades rurais foram encontradas pelo índice de Davies-Bouldin, o coeficiente k-means foi usado para delimitar com exatidão as fronteiras de cada agrupamento. Várias marcações foram realizadas nos mapas para melhor visualização e análises.

Pela separação em cores das classes obtidas pelo coeficiente de k-means, é possível visualizar a área no mapa compreendida por cada grupo. Com os hits de histograma podemos ver qual a parte do mapa que melhor corresponde aos dados. Através da frequência das classes inseridas no gráfico do coeficiente de k-means foi possível separar os dados de cada grupo.

Na Figura 19, temos a matriz unificada projetada das classes de k-means colorida (a), matriz unificada projetada das classes de k-means com hist inseridos preto e branco (b), matriz unificada projetada das classes de k-means com rótulos sem cores e marcações (c) e matriz unificada projetada das classes de k-means colorida com a separação das classes (d).

Figura 19 - Matriz unificada projetada das classes de k-means colorida (a), matriz unificada projetada das classes de k-means com hist inseridos preto e branco (b), matriz U projetada das classes de k-means com rótulos sem cores (c), matriz unificada projetada d



Fonte: Elaborado pelo autor.

Visualizando o mapa de modo geral, podemos observar que os neurônios próximos que foram ativados, ficaram bem distribuídos no mapa, sendo os grupos 1, 3 e 4 mais próximos e os grupos 2 e 3 mais distantes e o grupos 4 comum a todos. Os grupos 1 e 3 apresentaram tamanho e distribuição bem parecido.

Através dos hits de histograma (b), é possível observar no grupo 2, a área do mapa que melhor corresponde aos dados avaliados, mostra quantos dados foram mapeados para cada unidade, neurônio vencedor (BMU). Um BMU pode ser definido como o neurônio vencedor que melhor representa um determinado vetor de dados avaliados.

Ainda na Figura 19 através dos hits de histograma (b), é possível perceber que as distribuições dos dados de acidentes com máquinas agrícolas em vias públicas e propriedades rurais, em relação aos seus neurônios vencedores (BMUs) está compatível com a quantidade de dados, pois temos poucos neurônios inativos e aparentemente nenhum neurônio com sobrecarga no mapa.

Na Tabela 11 temos um maior detalhamento dos grupos dos acidentes com tratores e máquinas agrícolas em vias públicas e propriedades rurais, onde podemos observar quais as classes de indicadores foram mais frequentes dentro de cada grupo para o conjunto de dados avaliados.

Tabela 11 - Detalhamento dos grupos dos acidentes com tratores e máquinas agrícolas em vias públicas e propriedades rurais

Indicadores	Grupos				
	1	2	3	4	
Número de acidentes	421	723	392	225	
Região	Classe	Reg. Sul	Reg. Sul	Nordeste	Nordeste
	Freq. (%)	53,66	54,57	26,34	25,83
Horários	Classe	Per. Tarde	Per. Tarde	Manhã	Manhã
	Freq. (%)	34,01	39,13	32,48	50,64
Óbitos	Classe	Sem vitimas	Vit.Fatais	Vit.Fatais	Vit.Fatais
	Freq. (%)	77,86	84,39	67,51	73,92
Local	Classe	Via publica	Propriedade	Via publica	Propriedade
	Freq. (%)	55,80	83,02	95,11	95,47
Tipo	Classe	Colisão	Capotamento	Colisão	Capotamento
	Freq. (%)	29,66	43,01	30,95	46,59
Causa	Classe	D. Sinalização	D. Sinalização	D. Sinalização	D. Sinalização
	Freq. (%)	36,82	19,06	40,15	38,25
Idade	Classe	De 31 a 40	De 41 a 50	De 51 a 60	De 41 a 50
	Freq. (%)	9,95	18,15	8,18	10,71
Equipamento	Classe	Trator	Trator	Trator	Trator
	Freq. (%)	82,58	58,31	81,07	73,34

Fonte: Elaborado pelo autor.

Podemos observar que acidentes com máquinas agrícolas em propriedades rurais ou vias públicas, representam um risco muito grande, por sua capacidade de causar danos graves nos envolvidos, pois a classe mais frequentes para o indicador óbitos foi vítimas fatais,

ou seja, o acidente levou ao óbito da vítima.

Para Guinot et al. (2021), os tratores na agricultura são altamente vulneráveis à ocorrências de severos acidentes, podendo envolver mais de uma vítima com ferimentos graves ou fatais e gerar grandes danos econômicos aos agricultores.

Já Sousa et al. (2022), afirma que a condição das estradas é um fator que muito contribui para a ocorrência de um ou muitos acidentes, podendo resultar em vítimas com ferimentos graves, que pode levar à morte e perda total da máquina ou veículos envolvidos.

Diagnóstico de acidentes de trabalho com tratores agrícolas no estado do Rio Grande do Sul, pode constatar que 62% das causas de acidentes ocorreram devido a atos inseguros, com 33% dos óbitos ocorrendo devido ao capotamento ou tombamento (GUINOT et al., 2020).

Em relação à causa mais comum de acidentes com máquinas agrícolas, tanto em via pública como propriedade rural, foi desobediência à sinalização, mostrando a necessidade de campanhas educativas para tratoristas e de conscientização da população quanto aos riscos de acidentes com máquinas agrícolas.

Entre os principais causadores de acidentes, também podemos destacar a falta de condições mínimas de segurança na plataforma de operação, condições de trabalho insalubres, ausência de proteção individual, utilização incorreta de equipamentos e intoxicação por fitossanitários (SOUSA et al., 2022).

No grupo 1, os acidentes com máquinas agrícolas ocorrem, principalmente, na região Sul do país, no período da tarde, sem vítimas, em via públicas, por desobediência a sinalização, operadores com faixa etária de 31 a 40 anos de idade, com o trator sem implemento acoplado.

De acordo com essas informações, os operadores de máquinas agrícolas quando estiverem trafegando por vias públicas na região Sul devem seguir rigorosamente a sinalização das vias para evitar acidentes.

Vale a pena ressaltar também que nas pequenas e grandes cidades a presença de máquinas agrícolas é menor, sendo o mais comum os tratores empregados na construção civil, como as retroescavadeiras, por exemplo. Observação colaborada por Facchinetti et al. (2022).

De acordo com Bellochio *et al.* (2018), estudando acidentes com máquinas agrícolas, afirmam que mais de 50% dos acidentes com máquinas agrícolas ocorrem em vias públicas, colaborando com esse estudo.

Portanto, a presença de máquinas em vias públicas pode ser associada a necessidade de deslocamento das máquinas para atividades no campo de uma propriedade

para outra, principalmente em rodovias estaduais e federais.

Logo, Jarén et al. (2021) estudando acidentes com tratores agrícolas na Espanha durante a última década também reforça a constatação sobre a presença de máquinas agrícolas em vias públicas.

O grupo 2, diferente do grupo 1, os acidentes ocorreram principalmente em propriedades rurais e com vítimas fatais por capotamento devido desobediência a sinalização, com trator sem implemento no período da tarde, idade do operador de 41 a 50 anos, também na região Sul.

Outra coisa muito importante sobre o grupo 2, de acordo com os hits de histograma obtido na análise dos dados, é o grupo que mais representa o conjunto de dados avaliados, sendo o maior grupo obtido.

Macedo *et al.* (2018), avaliando sinistros em rodovias federais, também encontrou maior ocorrência de acidente nos estados correspondentes a essa região. Isso mostra a necessidade de realizar campanhas educativas para operadores nessa região, com o propósito prevenir e evitar a ocorrência de acidentes.

No grupo 3 os acidentes ocorreram, principalmente em vias públicas com colisão por desobediência a sinalização no período da manhã com o trator sem implemento, na região Nordeste, idade do operador de 51 a 60 anos. O grupo 3 também foi o grupo mais distante de todos, principalmente do grupo 2, o mais representativo dos dados.

No entanto, devemos considerar que os acidentes nesse grupo 3, ocorreram principalmente na região Nordeste, onde predomina a fruticultura irrigada e máquinas de menor porte. Já na região Sul, predomina máquinas de grande porte e a produção de grãos. Outro fato importante sobre esse grupo é a idade do operador, que foi maior do que a observada nos demais grupos.

De acordo com Bellochio *et al.* (2018), acidentes no trabalho representam importância social e econômica imensamente grande, seja pela incidência, idade dos acidentados, ou versatilidade da máquina e o seu crescente uso na agricultura que contribuíram para elevar o número de acidentes com vítimas graves.

O grupo 4 foi o menor grupo formado, no entanto, o mais próximo de todos. Nesse grupo, os acidentes ocorreram principalmente nas propriedades rurais, com vítimas fatais, com capotamento, devido à desobediência à sinalização, com trator sem implemento e pela manhã na região do Nordeste com operadores na faixa etária de 41 a 50 anos.

Outro resultado muito importante é que a metodologia foi capaz de separar claramente, os acidentes em vias públicas dos acidentes em propriedades rurais e também os

acidentes da região Nordeste dos ocorridos na região sul, indicando que na hora de traçar estratégias e campanha de prevenção, essas diferenças devem ser consideradas, pois são significativas dentro de cada grupo.

5 CONCLUSÃO

A técnica de agrupamento combinada à rede neural de mapas auto-organizável mostrou-se como uma ferramenta poderosa na análise de dados de acidente, permitindo uma análise exploratória mais segura e completa.

Os acidentes com máquinas agrícolas representam um risco muito grande por sua capacidade de causar danos graves aos envolvidos, pois a classe mais frequente para o indicador óbitos, foi vítimas fatais.

A causa mais comum de acidentes com máquinas agrícolas, tanto em via pública como rodovias federais, foi desobediência à sinalização, mostrando a necessidade de campanhas educativas tratorista e conscientização da população.

Os acidentes ocorridos nas regiões Sul e Nordeste, vias públicas e propriedades rurais, por mais que sejam similares, suas particularidades precisam ser levadas em consideração, principalmente em campanha de combate e conscientização.

REFERÊNCIAS

- ASHARI, I. F.; BANJARNAHOR, R.; FARIDA, D. R.; AISYAH, S. P. DEWI, A. P.; HUMAYA, N. Application of Data Mining with the K-Means Clustering Method and Davies Bouldin Index for Grouping IMDB Movies. **Journal of Applied Informatics and Computing (JAIC)**, [s. l.], v. 16, N.1, p. 07-15, 2022.
- AGRAMONTE, J. A. E. G.; MALPARTIDA, M. B. A. Caracterización de regiones espacialmente homogéneas de monóxido de carbono en Lima Metropolitana mediante el algoritmo de clustering k-means. **Biotech & Engineering**, [s. l.], v. 2788, n. 4295, p. 17-28, 2021.
- ANFAVEA. **Associação Nacional de Fabricantes de Veículos Automotores**. 2022. Disponível em: Acesso em: <https://acervo.anfavea.com.br/AcervoDocs/Anu%C3%A1rio%20ANFAVEA%202022-422-0.pdf>. 25 mai. 2022.
- ANTUNES, S.M.; CORDEIRO, C.; TEIXEIRA, H.M. Analysis of fatal acidentes with tractors in the Centre of Portugal: Ten years analysis. **Forensic Science International**, [s. l.], v. 287, p. 74-80, 2018.
- ARCOVERDE, G. F. B.; ALMEIDA, A. M.; XIMENES, A. C.; MAEDA, E. E.; ARAÚJO, L. S. Identificação de áreas prioritárias para recuperação florestal com o uso de rede neural de mapas auto-organizáveis. **Bol. Ciênc. Geod., sec. Artigos**, [s. l.], v. 17, no 3, p.389-400, 2011.
- ALBUQUERQUE, A.; PEREIRA, J. V.; MARTINS, R. About data analysis theory. **Brazilian Journal of Development**, [s. l.], v.7, n.2, p. 19814-19833, 2021.
- BARONTE, B. P. M. **Redes neurais recorrentes aplicadas à predição de valores de ações**. 2022. 62 f. Monografia (Graduação em Bacharel em Sistemas de Informação) - Centro de Ciências Exatas e Tecnologia, Universidade Federal do Estado do Rio de Janeiro, Rio de Janeiro, 2022.
- BATISTA, A. F. N. **Diagnóstico de faltas incipientes em transformadores de potência baseado na análise de gases dissolvidos no óleo isolante empregando redes neurais artificiais**. 2022. 83 f. Monografia (Graduação em Engenharia Elétrica) - Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista, Ilha solteira, 2022.
- BOYACI, M.; YILDIZ, O. Farm Safety Behaviors of Farmers in Izmir and Manisa Provinces in Turkey. **Eurasian Journal of Agricultural Economics**, [s. l.], v. 1, n. 1, p.27-40, 2021.
- BAESSO, M. M.; MODOLO, A. J.; BAESSO, R. C. E.; TROGELLO, E. Segurança no uso de máquinas agrícolas: Avaliação de riscos de acidentes no trabalho rural. **Brazilian Journal of Biosystems Engineering**, São Paulo, V. 12, n. 1, p. 101-109, jan./mar. 2018. Disponível em: <http://seer.tupa.unesp.br/index.php/BIOENG/article/view/622>. Acesso em: 10 jan. 2019.
- BELLOCHIO, S. D. C. B.; ALONÇO, A. DOS S.; DE VARGAS, F.; POSSEBON, G.; TIAGO GONÇALVES LOPES, T. G. “Estado da arte” sobre as publicações científicas envolvendo acidentes com tratores em vias públicas no brasil. **Revista Engenharia na Agricultura**, Visoça-MG, v. 26, n. 6, p. 541-554, 2018. Disponível em:

<https://doi.org/10.13083/reveng.v26i6.821>. Acesso em: 05 jan. 2019.

CÔRTEZ, E. G.; FRANTZ, R.; FROZZA, R. Desenvolvimento de uma aplicação para reconhecer significados de palavras homônimas utilizando redes neurais artificiais. **TECNO-LÓGICA**, Santa Cruz do Sul, v. 20, n. 2, p. 145-153, 2016. Disponível em: <https://online.unisc.br/seer/index.php/tecnologica/article/view/7428/4943>. Acesso em: 7 jan. 2019.

CARVALHO, N. A. S.; SOUZA, R. C.; EPPRECHT, E. K. Segmentação do mercado consumidor cativo alta e média tensão de uma distribuidora de energia elétrica: aplicação do mapa auto-organizável de Kohonen para descoberta de padrões de inadimplência do setor. **Exacta**, São Paulo, v. 14, n.3, p. 495-509, 2016.

CARVALHO, O.; OLIVEIRA, L. S.; CRUZ, G. Environmental impacts generated by modernization in the world agricultural system. **Revista SODEBRAS**, [s. l.], v. 4, n. 160, p. 1705-2019. 2019.

COSENZA, D. N., SOARES, A. A. V., ALCÂNTARA, A. E. M. D., SILVA, A. A. L. D., RODE, R., SOARES, V. P., & LEITE, H. G. Site classification for eucalypt stands using Artificial Neural Network based on environmental and management features. **CERNE**, [s. l.], v. 23, n. 3, 2017. Disponível em: http://www.scielo.br/scielo.php?pid=S0104-77602017000300310&script=sci_arttext. Acesso em: 05 jan. 2019.

CESVI BRASIL. **Segurança Viária**. Online. Disponível em: http://www.cesvibrasil.com.br/seguranca/biblioteca_dados.shtm. Acesso em: 02 jan. 2019.

CLARO, M. L.; VERAS, R.; SANTOS, L.; FRAZÃO, F. M.; FILHO, A. C.; LEITE, D.; Métodos computacionais para segmentação do disco óptico em imagens de retina: uma revisão. **Revista Brasileira de Computação Aplicada**, Passo Fundo, v.10, n.2, p.29-43, 2018. Disponível em: <http://seer.upf.br/index.php/rbca/article/view/8398/114114189>. Acesso em: 02 jan. 2019.

CARMO, N. R. M. Use of Artificial Neural Networks for GHI Forecasting. **Revista Virtual Química**, [s. l.], v. 14, v. 1, p. 56-60, 2022.

COMBERTI, L.; DEMICHELA, M.; BALDISSONE, G. A combined approach for the analysis of large occupational accident databases to support accident-prevention decision making. **Safety Science**, [s. l.], v. 106, n. 3, p. 191-202, 2018.

CARBONARI, R.; DI MAIO, R.; PIEGARI, E.; D'AURIA, L.; ESPOSITO, A.; PETRILLO, Z. Filtering of noisy magnetotelluric signals by SOM neural networks. **Physics of the Earth and Planetary Interiors**, [s. l.], v. 285, p. 12-22, 2018.

DANIATI UKI EKA SAPUTRI, D. U. E.; TAOPIK HIDAYAT, T.; MASTUROH, S. Clustering of Clean Water Needs in Indonesia for the 2012-2017 Period Using the K-Means Algorithm. **JURNAL SISFOTENIKA**, [s. l.], V. 12, n. 2, p. 2087-7897, 2022.

DUTRA, R. A.; REIS, E. L.; REIS, C.; FIDÊNCIO, P. H.; REIS, C. D. G.; DAMASCENO, O. I. C. Spatial and temporal analysis of physical and chemical data of superficial waters, by self-organizing maps (SOM). **Brazilian Journal of Development**, Curitiba, v.7, n.6, p.

57578-57594 jun. 2021.

FREIRE, V. H. W.; FLHO, C. J. A. B.; RABBANI, E. R. K. Análise do programa de extensão tecnológico de Pernambuco usando técnicas de aglomeração de dados. **Revista de Engenharia e Pesquisa Aplicada**, [s. l.], v. 7, n. 2, p. 118-128, 2022.

FURTUOSO, G. D. V.; SANTOS, M.; QUINTAL, R. S. Application of recurrent neural networks in the provision of time series: a study of stock exchange stock prices. **R. Gest. Anál.**, [s. l.], v. 11, n. 2, p. 25-36, 2022.

FACCHINETTI, D.; TESANTORO, S.; GALLI, L. E.; PESSINA, D. Agricultural Tractor Roll-Over Related Fatalities in Italy: Results from a 12 Years Analysis. **Sustainability**, [s. l.], V. 13, n. 1, p. 4536, 2021.

FERREIRA, et al. Análises de discussões sobre acidentes de trabalho nas operações com tratores agrícolas na região do alto sertão sergipano. *In*: BONATTO, F.; HOLZMANN, H. A.; DALLAMUTA, J. **Engenharias mecânicas e industrial: Gestão e simulação**. Ponta Grossa: Atena, 2018. p-145.

FERNANDES, V. L.; CAMPOS, M. V.; SOUZA, L. H.; FILHO, J. F. S. COLEN, F. Evaluation of noise levels of an agricultural tractor as a function of the removal radius and engine rotation. **Brazilian Journal of Development**, Curitiba, v. 8, n. 1, p. 5859-5868 jan. 2022.

FIGUEIRA1, S. R. F.; GALACHE1, V. O. Análise comparativa da competitividade das exportações de soja em grão do Brasil, Estados Unidos e Argentina. **Revista de Economia e Sociologia Rural**, [s. l.], v. 61, n. 1, p. 245-403, 2023.

Food and Agriculture Organization of the United Nations. **FAO**. (2019). FAOSTAT. Recuperado em 23 de novembro de 2019, de <http://faostat.fao.org>.

GODARZI, A. A.; AMIRI, R. M.; TALAEI, A.; JAMASB, T. Predicting oil price movements: A dynamic Artificial Neural Network approach. **Energy Policy**, [s. l.], v. 68, n. 1, p. 371-382, 2014.

GKRITZA, K.; KINZENBAW, C.R.; HALLMARK, S.; HAWKINS, N. An empirical analysis of farm vehicle crash injury severities on Iowa's public Road system. **Accident Analysis and Prevention**, United States, v.42, n.1, p.1392-1397, 2010.

GREENAN, M.; TOUSSAINT, M.; PEEK-ASA, C.; ROHLMAN, D.; RAMIREZ, M. The effects of roadway characteristics on farm equipment crashes: a geographic information systems approach. **Injury Epidemiology**, Colômbia, v.3, n.31, p.17, 2016. Disponível em: <https://injejournal.springeropen.com/articles/10.1186/s40621-0160096-1>. Acesso em: 09 jan. 2019.

GUIMARÃES, K. C.; MENDES, A. T.; SANTOS, R. O. G. Characterization of the profile of victims of traffic accidents on brazilian federal highways. **Brazilian Journal of Development**, Curitiba, v. 7, n. 6, p. 56385-56400, 2021.

GODOIS, L. M. **Um algoritmo para agrupamento de dados utilizando interação entre**

agetes. 2018. 56 f. Dissertação (Mestrado em engenharia computacional) – Programa de pós-graduação em engenharia computacional, Universidade Federal do Rio Grande, Rio Grande, 2018.

GOVENDER, P.; SIVAKUMAR, V. (2020). Application of k-means and hierarchical clustering techniques for analysis of air pollution: **A review** (1980–2019). *Atmospheric Pollution Research*, 11(1), 40-56.

GUINOT, K. O.; SCHLOSSER, J. F.; HERZOG, D.; BERTINATTO, R.; MOURA, N. B. Diagnóstico de acidentes de trabalho com tratores agrícolas no estado do rio grande do sul, brasil. **TECNO-LÓGICA**, [s. l.], v. 25, n. 2, p. 300-304, 2021.

HETTWER. H. R. A controversa evolução da indústria brasileira de máquinas agrícolas de 1920 a 2020. **Caminhos da História**. Montes Claros, v. 27, n. 1, p. 145-167, 2022.

JARÉN, C.; IBARROLA, A.; MANGADO, T.; ADIN, A.; ARNAL, P.; LÓPEZ-MAESTRESALAS, A.; ARAZURI, A. R. S. Fatal Tractor Accidents in the Agricultural Sector in Spain during the Past Decade. **Agronomy**, [s. l.], v.1, n. 1, p. 01-13, 2022.

KOHONEN, T. The self-organizing map. **Neurocomputing**, v. 21, n.1 p. 1-6, nov. 1998. Disponível em: Acesso em: 19 fev. 2016.

KANKAL, M.; AKPINAR, A.; KOMURCU, M. I. & OZSAHIN, T. S. (2011). **Modeling and forecasting of Turkey's energy consumption using socio-economic and demographic variables**. *Applied Energy*, 88(5), 1927-1939. Disponível em: http://repositorio.ufc.br/bitstream/riufc/6103/1/2010_tese_accsilva.pdf. Acesso em: 01 jan. 2019.

LIMA, I. O. **Espacialização dos acidentes com tratores nas regiões brasileiras**. 2016. 77 f. Dissertação (Mestrado em Engenharia Agrícola) – Centro de Ciências Agrárias, Universidade Federal do Ceará, Fortaleza, 2016. Disponível em: http://www.repositorio.ufc.br/bitstream/riufc/21964/1/2016_dis_iolima.pdf. Acesso em: 10 jan. 2019.

LANG, J.; TIAN, J.; ZHOU, Y.; Li, K.; CHEN, D.; HUANG, Q.; XING, X.; ZHANG, Y.; CHENG, S. A high temporal-spatial resolution air pollutant emission inventory for agricultural machinery in China. **Journal of Cleaner Production**, [s. l.], v. 183, n. 1, p. 1110-1121, 2018.

LOPES, A. G. C.; CORREIA, T. P. S.; BRITO, G. R.; FARIA, A. P. F. A.; SILVA, P. R. A.; Desempenho operacional e custo da subsolagem com e sem rodado duplo no trator agrícola. **Energia na Agricultura**, Botucatu, v. 35, n. 3, p. 317-329, 2020.

MACEDO, D. X. S.; Técnicas de agrupamento e redes neural em sinistros com máquinas na região sul. **South American Journal of basic education, technical and Technological**. Rio Branco, v. 6, n. 2, 2019.

MACEDO, D.X.S.; MONTEIRO, L.A.; SANTOS, V.C.; COSTA, E.; ALBIERO, D. Uso de técnicas de agrupamento e rede neural em sinistros com máquinas agrícolas nas rodovias federais paranaenses. **Energia na Agricultura**, [s. l.], v. 33, n. 1, p. 14-21, 2018.

MACEDO, D. X. S.; SANTOS, V. C.; MONTEIRO, L. A. M.; COSTA, E.; DUTRA, J. A. C.; UCHÔA, M. R.. Grouping techniques and neural network in machine claims in the southern region. **SAJEBTT**, [s. I.], v.6 n.2, p. 484-500, 2020.

MONTEIRO, L. A.; ALBIERO, D. **Segurança na operação com máquinas agrícolas**. 1ª edição: Fortaleza, impressa universitária da UFC, 2013.

MONTEIRO, L. A. Acidentes com tratores agrícolas. **Cultivar máquinas**, Pelotas, v. 10, n.5, p. 12-16, 2012.

MACEDO, D. X. S. Caracterização dos acidentes envolvendo tratores agrícolas nas rodovias federais brasileiras. 2014. 62 f. Dissertação (Mestrado em Engenharia Agrícola) – Centro de Ciências Agrárias, Universidade Federal do Ceará, Fortaleza, 2014. Disponível em: http://www.repositorio.ufc.br/bitstream/riufc/10579s_dxsmacedo.pdf. Acesso em: 10 jan. 2019.

MACEDO, D. X.S. **Uso de técnicas de agrupamento e rede neural em sinistros com máquinas agrícolas nas rodovias federais**. 2018. 161 f. Tese (Doutorado em Engenharia Agrícola) – Centro de Ciências Agrárias, Universidade Federal do Ceará, Fortaleza, 2018.

MINISTÉRIO DO ABASTECIMENTO PECUARIA E AGRICULTURA. Agricultura familiar. 2019. Disponível em: <http://www.agricultura.gov.br/agricultura-familiar>. Acesso: 11 maio de 201.

MACEDO, D. X. S.; SANTOS, V. C.; MONTEIRO, L. A. M.; COSTA, E.; DUTRA, J. A. C.; UCHÔA, M. R. Grouping techniques and neural network in machine claims in the southern region. **SAJEBTT**, [s. I.], v. 6 n. 2, p. 484-500, 2020.

MOURA, R.; BEER, M.; PATELLI, E.; LEWIS, J. Learning from major accidents: Graphical representation and analysis of multi-attribute events to enhance risk communication. **Safety Science**, [s. I.], v. 99, p. 58-70, 2018.

MARTINS, V.; PEDRI, E. C. M.; ANA APARECIDA BANDINI ROSSI, A. A. Characterization and grouping of cassava landraces from Northern Mato Grosso state, Brazil, through fruit characters. **Revista Thema**, [s. I.], v. 21, p. 2, 323-331, 2022.

MULERO, Á., PIERANTOZZI, M., CACHADIÑA, I., & DI NICOLA, G. (2017). An Artificial Neural Network for the surface tension of alcohols. *Fluid Phase Equilibria*. 449, 28-40.

MATOS, M.S.V; VALE, J.C.B.; MESQUITA, A.L.A. Reduction of number of simulations for parameters identification of DEM models using neural network and design of experiments. **Revista Matéria**, [s. I.], v.27, n. 1, p., 2022.

OLIVEIRA, Ariovaldo Umbelino. **A mundialização da agricultura brasileira**. São Paulo: Iände Editorial, 2016.

ORGANIZACIÓN INTERNACIONAL DEL TRABAJO (OIT). Panorama Laboral 2004: **Oficina Regional para las Américas y el Caribe**. Lima, 2004. 118p. Disponível em:

http://ilo.org/wcmsp5/groups/public/---americas/---rolima/documents/publication/wcms_187467.pdf. Acesso em: 01 jan. 2019.

ORISA, M. Optimasi Cluster pada Algoritma K-Means. **SENIATI**, [s. l.], V. 2788, n. 4295, p. 2085-4218, 2022.

PALAMARA, F. PIGLIONE, F. PICCININI, N. Self-Organizing Map and clustering algorithms for the analysis of occupational accident databases. **Safety Science**, Nicosia, v. 49, n. 8, p. 1215-1230, out. 2011.

PETROVIC, S. A comparison between the silhouette index and the Davies-Bouldin index in labelling IDS clusters. In: **NORDIC WORKSHOP SECURE IT SYSTEM**, 11., 2006, Sweden. **Anais...** Sweden: NordSec, 2006. p. 53-64. Disponível em: Acesso em: 9 nov. 2020.

PALMA, G. M. **Avaliação da viabilidade do uso de redes neurais artificiais para o desenvolvimento de um softsensor de biomassa de microalgas em fotobiorreator**. 2022. 91 f. (Mestrado em Engenharia Química) - Centro de Ciências Exatas e de Tecnologia, Universidade Federal de São Carlos, São Carlos, 2022.

PEREIRA, A. S.; REIS, A. V.; NINO, L. B.; GOMES, M. C.; FERREIRA, M. F. Cognitive mapping of ergonomics and safety on agricultural tractors used in family farming. **Revista de la Facultad de Agronomía**. La Plata, v. 120, n. 1, p. 01-14, 2021.

PEREIRA, A. S.; REIS, A. V.; FERREIRA, M. F.; MÁRIO CONILL GOMES, M. C.; OJEDA, E. Percepção dos agricultores familiares sobre ergonomia e segurança em tratores agrícolas. **TECNO-LÓGICA**, [s. l.], v. 24, n. nesp, p. 300-307, 2020.

ROQUE, A. Do neurônio biológico ao neurônio das redes neurais artificiais. Notas de Aula da Disciplina Psicologia Conexionista, Universidade de São Paulo, Ribeirão Preto, 2016. Disponível em: <http://sisne.org/Disciplinas/PosGrad/PsicoConex/aula3.pdf>. Acesso em: 02 jan. 2019.

Redes neurais artificiais. Rio de Janeiro: PUC-RIO, 2016. Disponível em: http://www.maxwell.vrac.puc-rio.br/5566/5566_6.PDF . Acesso em: 04 jan. 2019.

RODRIGUES, H. N.; CENTENO, L. N.; CECCONELLO, S. T. Clustering water quality data of a lagoon located in the South of Rio Grande do Sul. **Revista Thema**, [s. l.], V. 19, n. 1, p. 1-10, 2021.

RONDELLI, V.; CASAZZA, C.; MARTELLI, R. Tractor rollover fatalities, analyzing accident scenario. **Journal of Safety Research**, [s. l.], v. 67, p. 99-106, 2018.

RESTA, M.; SONNESSA, M.; TÀN FANI, E.; TESTI, A. Unsupervised neural networks for clustering emergent patient flows. **Operations Research for Health Care**, [s. l.], v. 18, p. 41-51, 2018.

RAMADHANI, S. R.; AZZAHRA, D.; TOMI Z. Comparison of K-Means and K-Medoids Algorithms in Text Mining based on Davies Bouldin Index Testing for Classification of Student's Thesis. **Jurnal Teknologi Informatika & Komunikasi Digital Zone**, [s. l.], v. 13, n.1, p. 24-33, 2022.

RINALDI, P.C.N.; FERNANDES, H.C.; TEIXEIRA, M.M.; CECON, P.R.; ALVAENGA, C.B. Diagnóstico da potência e torque dos tratores agrícolas fabricados e comercializados no Brasil. **Revista Engenharia na Agricultura**. Viçosa, v. 23, n. 3, p. 246-256, 2016.

RICARDO, A. S. **Confiabilidade de elementos e sistemas estruturais metálicos em situação de incêndio utilizando redes neurais artificiais adaptativas**. 2022. 184 f. Tese (Doutorado em Estruturas) - Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, 2022.

SANTOS, D. M.; PORTUGAL, E. M. L.; FROIS, J. G. F.; LIMA, R. R. The use of Arduino as a safe alternative in the handling of machines in the rural environment, especially the forage shredder. **International Journal of Geoscience, Engineering and Technology**, [s. l.], v. 5, n. 1, p. 40-44, 2022.

SEPTIANI, I. W.; FAUZAN, A.; HUDA, M. M. Implementasi Algoritma K-Medoids Dengan Evaluasi *Davies-BouldinIndex* Untuk Klasterisasi Harapan Hidup Pasca Operasi Pada Pasien Penderita Kanker Paru-Paru. **Jurnal Sistem Komputer dan Informatika (JSON)**, [s. l.], v. 3, n. 4, p. 556-566, 2022.

SOUSA, A. C. M.; OLIVEIRA, D. C.; PADILHA, A. S.; NACHTIGALL, G. R.; TATAGIBA, S. D.; HACKBARTH, D. Work accidents involving agricultural machines in Brazil: state of the art on the main causes of claims and actions aimed at prevention. **Brazilian Applied Science Review**, Curitiba, v. 6, n. 2, p. 1224-1233, 2022.

SANTOS, J. E. G; CAZANI, A. C.; ORTELAN, A. C. Localized vibration in a mechanical soil preparation system for family farming. **Brazilian Journal of Animal and Environmental Research**, [s. l.], v. 4, n. 2, p. 2445-2456, 2021.

SOUZA, D. C. R. **Aplicação de Redes Neurais Artificiais para Estimção de Indicadores de Segurança Estática e Dinâmica de Sistemas Elétricos de Potência**. 2022. 81 f. Dissertação (Mestrado Engenharia Elétrica e de Telecomunicações) - Escola de engenharia, Universidade Federal Fluminense, Niterói, 2022.

SILVA, A. G.; CASTRO, A. R. G.; VIEIRA, A. C. V. Modelo de previsão hidrológica utilizando redes neurais artificiais: um estudo de caso na bacia do Rio Xingu–Altamira-PA. **Revista Brasileira de Computação Aplicada**, Passo fundo, v.10, n.3, p.55–62, 2018. Disponível em: <http://http://seer.upf.br/index.php/rbca/article/view/8779/114114345>. Acesso em: 01 jan. 2019.

SILVA, L. A.; ARAÚJO, L. B. R.; BEZERRA, A. K. L.; MURTA, A. H. F.; BABADOPULOS, L. F. A. L.; JÚNIOR, M. S. M. Predictive modeling of the mechanical properties of concrete reinforced with steel fiber using artificial neural networks. **Ambiente Construído**, [s. l.], v. 22, n. 2, p. 215-232, 2022.

TIPIRISETTY, Abhinav. **Stock Price Prediction using Deep Learning**. Projetos de Mestrado. San Jose State University, 2018.

YOKOMIZO, G. K. I.; JÚNIOR, F. O. C.; HONGYU, K.; NETO, J. T. F. Estabilidade e adaptabilidade pelo uso combinado de dendrograma e AMMI em progênies de açaizeiro.

Biota Amazonia, [s. l.], v. 11, n. 1, p. 75-80, 2021.

ZAWACKI, M. P. **Acidentes de trabalho ocorridos no meio rural na comunidade de Espírito Santo, Alegria, RS**. 2017. 44 p. Trabalho de conclusão de curso. Faculdade de Ciências Econômicas da Universidade Federal do Rio Grande do Sul, Porto Alegre, 2017.

ZUPPINI, M. S. **Apreamento de debêntures ilíquidas utilizando redes neurais e clustering**. 2018. 55 f. Dissertação (Mestrado Profissional de Economia) – Escola de Economia de São Paulo da Fundação Getúlio Vargas, São Paulo, 2018. Disponível em: <https://bibliotecadigital.fgv.br/dspace/handle/10438/24761>. Acesso em: 10 jan. 2019.