

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”  
FACULDADE DE ENGENHARIA  
CÂMPUS DE ILHA SOLTEIRA**

**LUCIANO DUARTE SOUZA**

**Emissão de CO<sub>2</sub> do solo em pastos degradado, manejado e consórcio  
silvipastoril no Cerrado**

Ilha Solteira  
2020

**LUCIANO DUARTE SOUZA**

**Emissão de CO<sub>2</sub> do solo em pastos degradado, manejado e consórcio silvipastoril no Cerrado**

Tese apresentada à Faculdade de Engenharia de Ilha Solteira – UNESP como parte dos requisitos para obtenção do título de Doutor em Agronomia. Especialidade: Sistemas de Produção.

Prof. Dr. Alan Rodrigo Panosso  
**Orientador**

Prof. Dra. Érica de Oliveira Araújo  
**Co-orientador**

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

S729e Souza, Luciano Duarte.  
Emissão de Co2 do solo em pastos degradado, manejado e consórcio silvipastoril no cerrado / Luciano Duarte Souza. -- Ilha Solteira: [s.n.], 2020  
65 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Sistemas de Produção, 2020

Orientador: Alan Rodrigo Panosso  
Coorientador: Érica de Oliveira Araújo  
Inclui bibliografia

1. Dinâmica do carbono. 2. Respiração do solo. 3. Efeito estufa. 4. Inteligência artificial. 5. Atributos químicos do solo.

## CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: Emissão de CO<sub>2</sub> do solo em pastos degradado, manejado e consórcio silvipastoril no Cerrado

AUTOR: LUCIANO DUARTE SOUZA

ORIENTADOR: ALAN RODRIGO PANOSSO

COORIENTADOR: RAFAEL HENRIQUE PEREIRA DOS REIS

COORIENTADORA: ÉRICA DE OLIVEIRA ARAÚJO

Aprovado como parte das exigências para obtenção do Título de Doutor em AGRONOMIA, área: Sistemas de Produção pela Comissão Examinadora:

Prof. Dr. ALAN RODRIGO PANOSSO   
Departamento de Ciências Exatas / Faculdade de Ciências Agrárias e Veterinárias de Jaboticabal - UNESP

Prof. Dr. RAFAEL MONTANARI   
Departamento de Fitossanidade, Engenharia Rural e Solos / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof. Dr. MARCELO CARVALHO MINHOTO TEIXEIRA FILHO   
Departamento de Fitossanidade, Engenharia Rural e Solos / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof. Dr. DANIEL DE BORTOLI TEIXEIRA   
Campus de Marília / Universidade de Marília - UNIMAR

Dr. RICARDO DE OLIVEIRA BORDONAL   
Laboratório Nacional de Biorrenováveis - LNBR / Centro Nacional de Pesquisa e Energia em Materiais - CNPEM

Ilha Solteira, 22 de junho de 2020

## **AGRADECIMENTOS**

Gostaria de agradecer a minha família pelos ensinamentos ao longo da minha vida, ensinamentos estes, que fizeram com que eu alcançasse meus objetivos.

Ao meu orientador Dr. Alan Rodrigo Panosso pela sua dedicação e todo suporte para que eu conseguisse concluir o doutorado.

À Dra. Érica de Oliveira Araújo pela coorientação e auxílio e dedicação nessa trajetória.

Aos meus amigos do grupo de pesquisa, Deise Nogueira, Maria Elisa Vicentini e Renan Tavanti por todos os momentos vividos nessa jornada.

À Universidade Estadual Paulista “Júlio de Mesquita Filho” - UNESP, em especial Faculdade de Engenharia do Campus De Ilha Solteira por todo o suporte técnico científico que me possibilitaram conduzir e concluir o doutorado.

E a todos que contribuíram de forma direta ou indireta para que eu chegasse até aqui, a todos vocês o meu muito obrigado!

Luciano Duarte Souza

*“A ciência nada mais é do que percepção”*

Platão

## RESUMO

Os diferentes ecossistemas agrícolas modificam a dinâmica do carbono do solo, expresso pelas variações temporais da emissão de CO<sub>2</sub> do solo, enquanto as redes neurais geram modelos preditivo para explicar o padrão da variabilidade da emissão de CO<sub>2</sub> do solo. Assim, o presente trabalho teve por objetivo caracterizar a variabilidade temporal da emissão de CO<sub>2</sub>, temperatura e umidade do solo, e analisar o uso de Redes Neurais Artificiais na predição da variabilidade espacial – temporal da emissão de CO<sub>2</sub> do solo em função dos atributos químicos do solo, na estação de inverno e verão, em área de pastagem degradada, pastagem recuperada e sistema silvipastoril na região do Cerrado Sul-mato-grossense. Os resultados permitiram concluir que a temperatura do solo e a umidade do solo influenciaram nas variações das emissões de CO<sub>2</sub> do solo ao longo do tempo. A menor média de emissão de CO<sub>2</sub> foi obtida em área de pastagem manejada (0,973 μmol m<sup>-2</sup> s<sup>-1</sup>) no período de inverno, enquanto a maior média foi obtida no sistema silvipastoril (1,562 μmol m<sup>-2</sup> s<sup>-1</sup>). O sistema silvipastoril no Cerrado apresentou os maiores valores de emissão total de CO<sub>2</sub> (2,01 Mg ha<sup>-1</sup>) ao longo dos 35 dias de estudo na estação seca do ano. A análise de componentes principais apresenta-se como uma alternativa eficaz na discriminação de sistemas de produção e sua relação com as propriedades do solo. Este estudo mostrou que as RNAs forneceram modelos preditivos para explicar a variação espaço temporal da emissão de CO<sub>2</sub>. A complexidade das redes não influenciou na predição do CO<sub>2</sub>. O melhor desempenho foi observado no modelo individual na área de pastagem degradada com uma rede MLP. A umidade do solo e a temperatura contribuem para a explicação da variação temporal da respiração do solo.

**Palavras-chave:** Dinâmica do carbono. Respiração do solo. Efeito estufa. Inteligência artificial. Atributos químicos do solo.

## ABSTRACT

The different agricultural ecosystems modify the dynamics of soil carbon, expressed by the temporal variations of soil CO<sub>2</sub> emissions, while neural networks generate predictive models to explain the pattern of soil CO<sub>2</sub> emission variability. Thus, the present work aimed to characterize the temporal variability of CO<sub>2</sub> emission, soil temperature and moisture, and to analyze the use of artificial neural networks in the prediction of spatial - temporal variability of soil CO<sub>2</sub> emission as a function of soil chemical attributes, in the winter and summer season, in a degraded pasture area, recovered pasture and silvopastoral system in the Cerrado region of Mato Grosso do Sul. The results allowed to conclude that soil temperature and soil moisture influenced the variations of soil CO<sub>2</sub> emissions over time. The lowest mean CO<sub>2</sub> emission was obtained in a managed pasture area (0,973 μmol m<sup>-2</sup> s<sup>-1</sup>) in the winter period, while the highest average was obtained in the silvopastoral system (1,562 μmol m<sup>-2</sup> s<sup>-1</sup>). The silvopastoral system in the Cerrado presented the highest values of total CO<sub>2</sub> emission (2,01 Mg ha<sup>-1</sup>) over the 35 days of study in the dry season of the year. Principal component analysis is an effective alternative to discriminate production systems and their relationship with soil properties. This study showed that the ANNs provided predictive models to explain the space-time variation of CO<sub>2</sub> emissions. The complexity of the networks did not influence the CO<sub>2</sub> prediction. The best performance was observed in the individual model in the degraded pasture area with an MLP network. Soil humidity and temperature contribute to explain the temporal variation in soil respiration.

**Keywords:** Carbon dynamics. Soil respiration. Greenhouse effect. Artificial intelligence. Chemical attributes of the soil.

## LISTA DE FIGURAS

<b>Figura 1.</b> Rede neural artificial.....	22
<b>Figura 2.</b> Rede neural artificial – Linear.....	23
<b>Figura 3.</b> Estrutura geral da rede neural MLP feed forward.....	24
<b>Figura 4.</b> Estrutura básica do modelo GRNN. ....	25
<b>Figura 5.</b> Arquitetura do modelo RBFNN.....	25
<b>Figura 6.</b> Localização da área experimental em Selvíria, Mato Grosso do Sul, Brasil. .....	29
<b>Figura 7.</b> Aspectos gerais das áreas de pastagem degradada (A), pastagem manejada (B) e sistema silvipastoril (C) no Cerrado sul-matogrossense. ....	30
<b>Figura 8.</b> Sistema LI-8100 interligado à câmara de solos (A), e câmara para solo inserida sobre o colar de PVC (B). ....	31
<b>Figura 9.</b> Termômetro medidor de temperatura do solo concomitante ao sistema LI- 8100. ....	32
<b>Figura 10.</b> TDR - Hydrosense system, sistema portátil utilizado para avaliação da umidade do solo. ....	32
<b>Figura 11.</b> Arquitetura da rede neural – RBF- 14 neurônios na camada de entrada -39 camada intermediária e neurônio na camada de saída 1.....	35
<b>Figura 12.</b> Histogramas da respiração do solo para as áreas de pastagem degradada (a), pastagem manejada (b) e sistema silvipastoril (c), durante o período de 35 dias de junho a julho de 2018. ....	38
<b>Figura 13.</b> Variabilidade temporal da emissão de CO <sub>2</sub> , temperatura e umidade do solo ao longo do período de 35 dias de estudo. ....	39
<b>Figura 14.</b> Relação linear da respiração do solo em função da temperatura (a) e umidade (b) do solo para cada manejo estudado durante o período de avaliação. ..	42
<b>Figura 15.</b> Emissão total de CO <sub>2</sub> ao longo do período de 35 dias avaliados para as áreas de pasto degradado (PD), manejado (PM) e sistema silvipastoril (SI). ....	43
<b>Figura 16.</b> Gráfico da análise de componentes principais (PCA) com três dimensões mostrando os pesos dos sistemas de manejo (pontos), grupos (círculos) e atributos do solo (setas). Os pontos próximos correspondem as observações com pesos semelhantes nos componentes da PCA. O comprimento das setas indica a variação dos atributos do solo nos componentes, enquanto os pontos indicam a correlação entre eles.....	43

## LISTA DE TABELAS

<b>Tabela 1.</b> Estatística descritiva da emissão de CO <sub>2</sub> do solo ( $\mu\text{mol m}^{-2} \text{s}^{-1}$ ).....	38
<b>Tabela 2.</b> Valores médios de respiração, temperatura e umidade do solo para todos os dias avaliados nas áreas de pastagem degradada (PD), pastagem manejada (PM) e sistema silvipastoril (SI).....	41
<b>Tabela 3.</b> Resultado da análise de fatores contendo os três primeiros fatores (processos) com suas cargas fatoriais que representam os coeficientes de correlação entre os atributos do solo em cada fator. ....	44
<b>Tabela 4.</b> Cenário 1: Modelo Global. Resumo das análises estatísticas realizadas para os vários modelos de redes neurais artificiais (RNAs). ....	47
<b>Tabela 5.</b> Cenário 2: Modelo Global com análise de componentes principal. Resumo das análises estatísticas realizadas para os vários modelos de redes neurais artificiais (RNAs). ....	48
<b>Tabela 6.</b> Coordenadas fatoriais das variáveis, baseadas nas correlações corresponde ao modelo global do cenário 2.....	48
<b>Tabela 7.</b> Pastagem degradada (PD). Resumo das análises estatísticas realizadas para os vários modelos de redes neurais artificiais (RNAs). ....	49
<b>Tabela 8.</b> Pastagem Manejada (PM). Resumo das análises estatísticas realizadas para os vários modelos de redes neurais artificiais (RNAs). ....	50
<b>Tabela 9.</b> Sistemas Silvipastoril (SI). Resumo das análises estatísticas realizadas para os vários modelos de redes neurais artificiais (RNAs). ....	51
<b>Tabela 10.</b> Análise de Sensibilidade com classificação dos atributos do solo (programa Statistica <sup>7</sup> ® no modo Intelligent Problem Solver (IPS). ....	53

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	<b>11</b>
<b>2</b>	<b>REVISÃO DE LITERATURA</b> .....	<b>14</b>
<b>2.1</b>	<b>Efeito Estufa e a Agropecuária</b> .....	<b>14</b>
<b>2.2</b>	<b>Emissão de CO<sub>2</sub> do Solo</b> .....	<b>16</b>
<b>2.3</b>	<b>Variabilidade Espacial da Emissão de CO<sub>2</sub> do Solo</b> .....	<b>17</b>
<b>2.5</b>	<b>Redes Neurais</b> .....	<b>19</b>
<b>2.6</b>	<b>Neurônio Artificial</b> .....	<b>20</b>
<b>2.7</b>	<b>Estrutura das Redes Neurais Artificiais</b> .....	<b>21</b>
<b>2.8</b>	<b>Arquitetura de Redes Neurais Artificiais</b> .....	<b>23</b>
2.8.1	<i>Rede Linear (LNN)</i> .....	23
2.8.2	<i>Rede Neural Perceptron Multicamadas (MLPNN)</i> .....	23
2.8.3	<i>Rede Neural de Regressão Generalizada (GRNN)</i> .....	24
2.8.4	<i>Rede Neural Função de Base Radial (RBFNN)</i> .....	25
2.8.5	<i>Treinamento supervisionado e não supervisionado</i> .....	26
<b>3</b>	<b>MATERIAL E MÉTODOS</b> .....	<b>28</b>
<b>3.1</b>	<b>Área Experimental</b> .....	<b>28</b>
<b>3.2</b>	<b>Determinação da emissão de CO<sub>2</sub> do solo, temperatura e umidade do solo</b> .....	<b>30</b>
<b>3.3</b>	<b>Amostragem e análise química do solo</b> .....	<b>32</b>
<b>3.4</b>	<b>Processamento e análise de dados</b> .....	<b>33</b>
3.4.1	<i>Variabilidade temporal da emissão de CO<sub>2</sub>, temperatura e umidade do solo</i> ..	33
3.4.2	<i>Análise de componentes principais (ACP)</i> .....	33
3.4.3	<i>Redes neurais artificiais na predição da variabilidade espacial-temporal da emissão de CO<sub>2</sub> do solo.</i> .....	34
3.4.4	<i>Crítérios de avaliação de desempenho das RNAs</i> .....	36
<b>4</b>	<b>RESULTADOS E DISCUSSÃO</b> .....	<b>36</b>

<b>4.1</b>	<b>Variabilidade temporal da emissão de CO<sub>2</sub>, temperatura e umidade do solo</b>	<b>37</b>
<b>4.2</b>	<b>Análise de componentes principal da variabilidade espaço- temporal da emissão de CO<sub>2</sub> do solo</b>	<b>43</b>
<b>4.3</b>	<b>Redes Neurais Artificiais na predição da variabilidade espaço- temporal da emissão de CO<sub>2</sub> do solo</b>	<b>47</b>
<b>5</b>	<b>CONCLUSÕES</b>	<b>54</b>
	<b>REFERÊNCIAS</b>	<b>54</b>

## 1 INTRODUÇÃO

Nas últimas décadas, o aumento na concentração dos gases do efeito estufa (GEE), principalmente o dióxido de carbono (CO<sub>2</sub>), o metano (CH<sub>4</sub>) e o óxido nitroso (N<sub>2</sub>O), promoveram mudanças climáticas que vem causando grande impacto nos ecossistemas naturais, em todo o planeta (IPCC, 2019). Em escala global, a queima de combustíveis fósseis é considerada a principal fonte de emissão de CO<sub>2</sub> para a atmosfera, e, no contexto brasileiro, o setor agropecuário ligado às mudanças de uso da terra e florestas, somente em 2012, contribuíram com cerca de 37 e 15% das emissões de CO<sub>2</sub> do Brasil, respectivamente (BRASIL, 2017).

O processo de perda de carbono do solo para a atmosfera é denominado emissão de CO<sub>2</sub> do solo (FCO<sub>2</sub>), ou respiração do solo, resultante da atividade microbiana (oxidação química) e respiração das raízes, sendo considerada a segunda maior fonte de CO<sub>2</sub> para atmosfera, atrás apenas dos oceanos (LAL, 2009). A perda do estoque de carbono do solo via FCO<sub>2</sub> é influenciada principalmente pelo uso e manejo dos solos, podendo causar impactos significativos na concentração de CO<sub>2</sub> da atmosfera (OLIVEIRA, 2018). Estimativas têm apontado que, devido ao uso e mudança no uso da terra, geralmente associado a práticas agrícolas, uma quantidade significativa de GEE é emitida pelo Brasil, valores na ordem de 2,7 Mg C ha<sup>-1</sup> a 6 Mg C ha<sup>-1</sup> ano tem sido relatados em áreas de pastagens (BERNOUX *et al.*, 2004). A conversão de ecossistemas nativos para fins agrícolas é reconhecidamente uma prática que causa grandes perdas de Carbono (C), contudo, o solo quando manejado adequadamente atua como sumidouro de C, dependendo, portanto das práticas de cultivo e manejo do solo em culturas (DOLAN *et al.*, 2006; OGLE; PAUSTIAN, 2005).

O Brasil se apresenta como um importante produtor mundial de alimentos e com grande potencial de expansão da oferta. Em 2019 foram 244,3 milhões de hectares na produção agropecuária, sendo 158,3 milhões de hectares destinados à pecuária, exclusivamente áreas de pastagens, no quais cerca de 4,2 milhões de hectares apresentam grau de degradação e 9,2 milhões de hectares precisam de recuperação (MAPA, 2019). Nesse cenário, a pecuária é uma das atividades que contribui com a emissão de GEE, e nesse sentido, uma das estratégias para reduzir emissão desses gases em áreas de pastagem é propor a diversificação estratégica das atividades da agricultura e pecuária no sentido de beneficiar ambos (OLIVEIRA, 2018). Nos sistemas integrados de cultivo, o efeito sinérgico entre pastagens, floresta

e lavoura apresenta potencial para aumentar os estoques de C no solo, reduzir as emissões de GEE para atmosfera, verticalizar a produção agropecuária, reduzir as pressões de desmatamento nas áreas de expansão agrícola e conseqüentemente conferir a sustentabilidade ao sistema produtivo (CARVALHO *et al.*, 2010).

O grande gargalo da pecuária brasileira em relação à emissão de CO<sub>2</sub> é o uso de pastagens degradadas. As pastagens que não disponibilizam de um adequado manejo têm apresentado uma redução no teor de carbono no solo (CARVALHO *et al.*, 2010), e conseqüentemente essa redução leva à emissão de CO<sub>2</sub> na atmosfera, pois perde quantidades significativas de matéria orgânica (EMBRAPA, 2015). Estima-se que de 12 a 25% do C do solo é perdido para atmosfera e quando avaliadas em pastagens degradadas essas perdas chegam a valores de 60 a 90%. Figueiredo *et al.* (2016) quando compararam pastagens bem manejadas com pastagens degradadas, verificaram que a pastagem degradada emitiu mais CO<sub>2</sub> que uma pastagem bem manejada, pois essas pastagens fixam menos C e conseqüentemente liberam mais CO<sub>2</sub> para a atmosfera, sendo assim, torna-se muito importante escolher bem as práticas de manejo nas áreas de pasto para que essas reduzam as perdas excessivas de dióxido de carbono do solo. Assim, recuperar uma pastagem degradada e torná-la uma pastagem bem manejada representa vantagem no aspecto de retirada de CO<sub>2</sub> atmosférico (CARDOSO, 2012), e o uso de espécies arbóreas em consórcio com forrageiras, como se observa no sistema silvipastoril, também apresenta grande potencial para a mitigação de gases de efeito estufa (ALARI, 2016).

O neurônio artificial tem como base neurônio biológico, dessa forma, uma rede neural artificial (RNA) nada mais que é que um grupo ou uma série de neurônios artificiais que estão conectados entre si, de modo que consigam interagir de forma combinada (FREITAS, 2016). Em suma, as redes neurais simulam o processo de decisão que as células nervosas (neurônios) do sistema nervoso central fazem (GRAUPE, 2013). Em sua definição mais ampla, uma rede neural artificial é definida por Haykin (2001) como “processadores paralelamente distribuídos, constituídos de unidades de processamento simples, que têm uma propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso”. Haykin (2001) em sua definição destaca dois aspectos em que a RNA se assemelha ao cérebro humano, sendo a primeira em que o conhecimento é adquirido pela RNA com base no seu ambiente por meio de um processo de aprendizado e o segundo é que as forças de

conexão entre neurônios, conhecidas como pesos sinápticos são utilizadas para armazenar o conhecimento adquirido.

A capacidade de aprendizagem que as RNAs possuem de aprender por meio de exemplo e de generalizar as informações aprendidas, as torna um excelente instrumento que propõem soluções interessantes em diversas áreas do conhecimento, inclusive na agronomia. As redes neurais podem ser de única camada ou múltiplas camadas. As redes utilizadas nesta pesquisa é uma rede neural de múltiplas camadas chamadas de MLP (Multilayer Perceptron), GRNN (Generalized Regression Neural Networks), Linear (Linear Network) e RBF (Radial Basis Function), utilizadas com sucesso para a solução de vários problemas envolvendo altos graus de não linearidade.

Contudo, na agricultura a maioria dos dados ecológicos e das variáveis envolvidas no processo de emissão de CO<sub>2</sub> (FCO<sub>2</sub>) apresenta certo grau de complexidade e não-linearidade e ainda sofrem a interferência com a variabilidade de parâmetros relevantes como a composição do solo, a temperatura e a umidade. Uma possibilidade realizável para representar situações de não-linearidade, complexidade e variabilidade é a utilização de Redes Neurais Artificiais (RNAs), visto que poucos são os trabalhos que quantificam ou estimam a emissão de CO<sub>2</sub> do solo, bem como a utilizam de redes neurais, em áreas de pastos degradados, recuperado e consórcio silvipastoril em área de Cerrado em Sul-matogrossense. Assim, com a adequação das Redes Neurais Artificiais para avaliar os dados coletados, será possível contribuir com a análise criteriosa das áreas, pois a previsão realizada pela rede poderá auxiliar em ações que visem reduzir a emissão de CO<sub>2</sub> na atmosfera.

Este estudo tem por hipótese que os diferentes sistemas agrícolas modificam a dinâmica do carbono do solo, expresso pelas variações temporais da emissão de CO<sub>2</sub> (FCO<sub>2</sub>) do solo, enquanto que as redes neurais geram modelos preditivo para explicar o padrão da variabilidade da emissão de CO<sub>2</sub> do solo, a partir dos seus atributos químicos. O objetivo do estudo foi caracterizar a variabilidade temporal da emissão de CO<sub>2</sub>, temperatura e umidade do solo, e analisar o uso de Redes Neurais Artificiais na predição da variabilidade espacial – temporal da emissão de CO<sub>2</sub> do solo em função dos atributos químicos do solo, em área de pastagem degradada, pastagem manejada e sistema silvipastoril com Aroeira-vermelha (*Schinus terebinthifolius*) na região do Cerrado Sul-mato-grossense.

## 2 REVISÃO DE LITERATURA

### 2.1 Efeito Estufa e a Agropecuária

Aliada ao desmatamento, a agropecuária é uma das principais responsáveis pela emissão dos GEE e em especial o dióxido de carbono (CO<sub>2</sub>), o metano (CH<sub>4</sub>) e o óxido nitroso (N<sub>2</sub>O). Segundo o relatório do painel Intergovernamental sobre Mudança do clima - (IPCC, 2019), a agricultura, o desmatamento, as atividades pecuárias entre outros usos da terra, representaram cerca de 13% das emissões de CO<sub>2</sub>, 44% das emissões de metano (CH<sub>4</sub>) e 82% das emissões de óxido nitroso (N<sub>2</sub>O). A resposta natural da terra à mudança ambiental induzida pelo homem causou um sumidouro líquido de cerca de 12 Gt CO<sub>2</sub> ano<sup>-1</sup> durante 2007-2016 (equivalente a 29% das emissões totais de CO<sub>2</sub>).

As emissões atmosféricas de GEE acompanham o crescimento do produto interno bruto bem como da população dos diferentes países, e nesse cenário, destacam-se como maiores emissores de carbono, o EUA, a China e a Rússia. O Brasil representa 3,8% das emissões mundiais (aproximadamente, 1.345 milhões de t de CO<sub>2</sub>eq, em 2012), no qual o setor agropecuário e o uso dos solos e florestas são responsáveis por 470 mil t de CO<sub>2</sub>eq e 370 mil t de CO<sub>2</sub>eq, respectivamente, em 2012 (VITAL, 2018).

O bioma Cerrado é o segundo maior ecossistema da América do Sul, com extensão de 2 milhões de km<sup>2</sup>, perdendo apenas para a Amazônia. Quase metade da área de Cerrado (41,2%) foi convertida em pastagens ou áreas agrícolas, e segundo Noojipady *et al.* (2017) os estoques de carbono no solo do Cerrado representam uma importante fonte nas emissões de GEE no Brasil.

No cenário de emissão de GEE, o setor de agropecuária e floresta não se destacam somente por contribuírem para as perdas de carbono para atmosfera, mas também pela possibilidade de atuarem como sumidouros de carbono, sendo assim, considerado em alguns cenários como agentes mitigadores. De acordo com Ussiri e Lal (2009), o que define o solo como fonte ou sumidouro de carbono é o tipo de uso e manejo. Rayment; Jarvis, (2000) salientam que o balanço de carbono de um ecossistema, ou seja, o que define se ele funciona como fonte ou sumidouro, consiste na diferença entre dois importantes componentes, que são semelhantes quanto a magnitude, mas diferentes quanto ao sentido, isto é, a fotossíntese e a respiração,

onde a primeira é responsável pela captura e a segunda pela perda de carbono para atmosfera. Assim sendo, por menor que seja o acréscimo das taxas de respiração do solo ocasionados por ações antrópicas, já podem ser mais que o suficiente para que um ecossistema mude o seu papel dentro do ciclo do carbono.

Costa *et al.* (2008) ao avaliarem o efeito do preparo do solo e do sistema de plantio direto sobre o estoque de carbono e a emissão de CO<sub>2</sub> do solo, concluíram que a adição de diferentes resíduos vegetais à solo influencia nas quantidades do estoque de carbono e que o preparo convencional atua como fonte de CO<sub>2</sub> para atmosfera.

Figueiredo *et al.* (2016) quando compararam pastagens bem manejadas com pastagens degradadas, verificaram que a pastagem degradada emitiu mais CO<sub>2</sub> que uma pastagem bem manejada, pois essas pastagens fixam menos C e conseqüentemente liberam mais CO<sub>2</sub> para a atmosfera, sendo assim, torna-se muito importante escolher bem as práticas de manejo nas áreas de pasto para que essas reduzam as perdas excessivas de dióxido de carbono do solo. Sistemas silvipastoris podem apresentar um balanço anual de carbono positivo (ROCHA *et al.*, 2017). Estes mesmo autores observaram um estoque médio de 16,12 t CO<sub>2</sub>e ha<sup>-1</sup>ano<sup>-1</sup>, demonstrando assim, uma alternativa eficiente na mitigação de gases do efeito estufa. Oliveira (2018) em sistema silvipastoril observou menor média de emissão de CO<sub>2</sub>, menor estoque de carbono e menor grau de humificação da matéria orgânica, e melhores características físicas do solo, em comparação a floresta plantada de eucalipto.

Neste sentido, como estratégias que visem o aumento do sequestro de carbono, pode-se destacar ações que tenham como objetivo minimizar a decomposição e a mineralização do carbono orgânico presente no solo. Essas ações podem ser tomadas por meio de estratégias que promova a proteção do carbono. Além disso, também é importante oferecer alimento (grãos e forragens) de qualidade para os animais, optar pelo manejo correto da pastagem, todas essas práticas irão aumentar a eficiência do setor produtivo o que culminará em um menor impacto ambiental.

## 2.2 Emissão de CO<sub>2</sub> do Solo

Com aproximadamente 3,3 vezes mais carbono que a atmosfera, o solo, é tido como um dos mais importantes reservatórios de carbono (WALLACE; HOBBS, 2006). Isso só é possível graças a interações complexas que ocorrem entre os microrganismos com qualidade e quantidade do material orgânico que é depositado ou incorporado ao solo em conjunto com a dinâmica da temperatura e umidade (SARTORI *et al.*, 2006).

Lal (2015) reforça que o estoque de carbono no solo ocorre por conta do balanço entre as entradas e as saídas de carbono no solo, de modo que, as entradas são consequências da decomposição de resíduos vegetais, raízes ou fertilizantes orgânicos. Por outro lado, as perdas de carbono na forma de CO<sub>2</sub> ocorrem por meio da mineralização da matéria orgânica e de resíduos vegetais (SIX *et al.*, 2006).

As condições climáticas, edáficas e as mudanças no uso da terra (como a conversão de áreas de floresta nativa para uso agrícola ou da pecuária) são importantes fatores na compreensão do processo de fluxo do CO<sub>2</sub> do solo para a atmosfera (FRANK *et al.*, 2006). As mudanças no fluxo de CO<sub>2</sub> (FCO<sub>2</sub>) são controladas por inumeráveis fatores de natureza física, química e biológica do solo, como a densidade (SAIZ *et al.*, 2006), teor de matéria orgânica do solo (MOS), estoque de carbono (PANOSSO *et al.*, 2011a), pH (RETH *et al.*, 2005), capacidade de troca catiônica (XAVIER *et al.*, 2019) e teores de óxidos de ferro do solo (LA SCALA *et al.*, 2000). No entanto, a umidade, temperatura do solo e a relação entre ambas e com os demais atributos constituem as principais variáveis que governam o FCO<sub>2</sub> (KANG *et al.*, 2003; SMITH *et al.*, 2018).

A temperatura do solo atua diretamente no metabolismo do solo incrementando as taxas de atividade microbiana e respiração das raízes, além disso, produtos oriundos de mineralização sob altas temperaturas podem ser mais recalcitrantes do que encontrados em ambientes temperados. Portanto a temperatura favorece maiores taxas de atividade microbiológica, contanto que os outros fatores que controlam a atividade não estejam em condições limitantes (MEIXNER; YANG, 2006).

A umidade do solo exerce uma importante função na decomposição da matéria orgânica do solo, pois atuam na dissolução, turgidez e fornecimento de nutrientes, além de favorecer a mobilidade dos microrganismos, permitindo assim que os fungos e bactérias desempenhem suas atividades metabólicas (MEIXNER; YANG, 2006). A

relação positiva entre a emissão de CO<sub>2</sub> e a umidade do solo, ou seja, quanto maior a umidade maior o FCO<sub>2</sub> foram constatados por Morrell *et al.* (2010), Oliveira (2018) e Panosso *et al.* (2009). No entanto, influência negativa da umidade no FCO<sub>2</sub> quando estas foram associadas à ocorrências de precipitação pluvial também são verdadeiras (PANOSSO *et al.*, 2011a; WANG *et al.*, 2015), fenômeno observado devido ao efeito físico de expulsão e difusão do gás CO<sub>2</sub> dos macroporos e preenchimento deste por água (CHEN *et al.*, 2010).

Em adição a isto, a umidade do solo pode desempenhar uma função de inibição na produção de CO<sub>2</sub>. Autores sugerem que o conteúdo ótimo de ar no solo está próximo quando os macroporos estão praticamente cheios de ar, favorecendo a difusão de O<sub>2</sub> no solo, e os microporos próximos da capacidade de retenção de água, favorecendo a solubilidade dos substratos utilizados pelos microrganismos (LUO; ZHOU, 2006). Contudo, se o conteúdo de água no solo não estiver adequado, este atributo pode limitar o FCO<sub>2</sub>, mesmo em condições em que a temperatura esteja ótima para a atividade microbiana (GARTEN *et al.*, 2009). Demonstrando assim que o entendimento dessas duas variáveis e as relações entre si tornam de suma importância para a compreensão do FCO<sub>2</sub> e que esses fatores variam ao longo do tempo (HU *et al.*, 2011), fazendo com que a compreensão das relações que regem o FCO<sub>2</sub> torne-se complexa e de difícil elucidação apesar de todos os esforços e respostas alcançadas nos últimos anos.

### **2.3 Variabilidade Espacial da Emissão de CO<sub>2</sub> do Solo**

Na estatística clássica, Dasselaar *et al.* (1998), assumem a variabilidade em torno da média como aleatória e espacialmente independente. Entretanto, em estudos dentro da ciência do solo a variabilidade pode ser discriminada como uma função da distância que separa uma amostragem da outra (ISAAKS; SRIVASTAVA, 1989; TRANGMAR *et al.*, 1986) é importante destacar isso porque a variabilidade de inúmeros atributos do solo apresenta com frequência uma componente espacialmente dependente. Por exemplo, a caracterização da emissão de CO<sub>2</sub> do solo via geoestatística, permite o acesso a informações importantíssimas acerca da sua distribuição espacial, contribuindo na compreensão da dinâmica do CO<sub>2</sub> entre o solo e a atmosfera (BRITO *et al.*, 2009; PANOSSO 2011b; MOITINHO *et al.*, 2015). É importante salientar, que as propriedades que atuam nos processos de produção e

transporte de CO<sub>2</sub> detém também de variabilidade espacial, tal fato, torna complexa as explicações em torno da variabilidade espacial da emissão de CO<sub>2</sub> (PANOSSO, 2011b).

Mudanças na variabilidade espacial das emissões de GEE, em um curto espaço de tempo, podem estar relacionadas aos fatores controladores desta variabilidade apresentarem grande dinâmica ou alta sensibilidade das as emissões a pequenas alterações destes fatores, como, por exemplo, a umidade do solo (DASSELAAR *et al.*, 1998). Em um estudo realizado por Rochette *et al.* (1991) foi possível verificar que os padrões espaciais da emissão de CO<sub>2</sub> do solo muda em função do teor de água no solo, desse modo, sofrendo grande influência dos eventos de precipitação, sobretudo após longos períodos de seca.

Rubio e Detto (2017), avaliando a variabilidade espacial e temporal da respiração solo em uma floresta tropical, observaram um alto grau de variabilidade espacial e temporal dos efluxos de CO<sub>2</sub> do solo. Oliveira (2018) e Ramos (2018) constataram que a emissão de CO<sub>2</sub> do solo apresentou correlação espacial significativa com o estoque de carbono do solo, e que o uso de sistemas integrados, como sistemas silvipastoris, apresentam atributos do solo favoráveis à manutenção do carbono no solo, devido ao seu baixo FCO<sub>2</sub>, constituindo assim um sistema indicado para a captura e armazenamento de carbono, e, conseqüentemente, mitigação do efeito estufa adicional. Vicentini *et al.* (2019) caracterizando os padrões temporais de emissão de CO<sub>2</sub>, temperatura e umidade do solo bem como, suas relações, em áreas de florestas plantadas de eucalipto, pinus e mata ciliar reflorestada no Bioma Cerrado verificaram que a precipitação pluvial e a umidade do solo influenciaram nas variações das emissões de CO<sub>2</sub> do solo nos diferentes sistemas.

Em adição, a estimativa dos valores de um atributo em locais não amostrados nas áreas experimentais ocorre por meio de técnicas como a krigagem ordinária através da interpolação dos valores, podendo mapear os atributos do solo dentro de uma área, o que permite indicar alternativas de manejo que reduzam o efeito da variabilidade sobre as culturas (BASARIR *et al.*, 2010, SANTOS *et al.*, 2012), além de ser o método mais utilizado para a interpolação de valores da emissão de CO<sub>2</sub> (BRITO *et al.*, 2010). Apesar de uma vasta literatura já publicada neste campo do conhecimento, incertezas na quantificação da emissão de CO<sub>2</sub> sob áreas agrícolas ainda necessitam de esforços, visto que, a relação da emissão de CO<sub>2</sub> do solo com fatores ambientais, climáticos em conjunto com os atributos químicos e físicos dos

solos tornam essa interação bastante complexa, o que acaba afetando na variação espaço-temporal da emissão de CO<sub>2</sub> (GRAF *et al.*, 2012).

## 2.4 Análises de Componentes Principais

A análise de componentes principais – ACP ou PCA (do inglês *Principal component analysis*) trata-se de uma técnica estatística capaz de representar dados multivariados em um subespaço de dimensão reduzido, de modo que a distância entre os pontos, que representam as amostras nesse subespaço, corresponda o tanto quanto possível às dissimilaridades entre os pontos no espaço de dimensão original (SILVA *et al.*, 2001).

O uso da análise de componentes principais para definir um espaço de fatores que englobe os dados, não causa nenhuma modificação nos dados, isso porque, o real objetivo consiste em identificar um sistema de coordenadas adequado, sendo capaz de remover ruídos dos dados sem causar nenhuma distorção nos mesmos (NETO; MOITA, 1998).

Em suma, a análise de componentes principais denota uma transformação de coordenadas de um conjunto de variáveis originais que são correlacionadas em um conjunto de variáveis artificiais descorrelacionadas, as quais chamamos de componentes principais (HAIR *et al.*, 2009). Nessa perspectiva, cada componente consiste na combinação linear das variáveis originais. É importante ressaltar que todas as componentes principais apresentam ortogonalidade entre si, dessa forma, não havendo informações repetidas. Portanto, a análise de componentes principais tenta, paralelamente, achar no espaço dimensional transformado a direção ao longo do qual os pontos encontram-se distribuídos com variabilidade máxima e manter a informação dos dados originais (HAIR *et al.*, 2009; SILVA *et al.*, 2001).

## 2.5 Redes Neurais

Denominamos modelos matemáticos análogos às estruturas neurais biológicas de redes neurais artificiais, as conhecidas RNAs. Isso só é possível graças ao surgimento de aparatos computacionais com capacidade de aprendizado e generalização (FREITAS, 2016). Dessa forma, as redes neurais artificiais atribuem aos neurônios biológicos a posição de unidades de processamento, que tem como

objetivo e função natural armazenar o conhecimento experimental e fazer com que seja possível usá-lo. Em outras palavras, a capacidade humana de aprender e generalizar fatos (padrões) é imitada pelas RNAs por meio da produção de saídas específicas para as entradas que não estavam presentes no processo de treinamento (KOVACS, 2006).

Os princípios básicos das redes neurais artificiais (RNAs) foram formulados pela primeira vez em 1943 por McCulloch e Pitts. O primeiro princípio diz que a atividade de um neurônio (RNA) é tudo ou nada, o segundo que um certo número fixo de sinapses maior do que 1 tem de ser excitado dentro de um determinado intervalo de adição neural para um neurônio para ser excitada, já o terceiro afirma que o único atraso significativo dentro do sistema neural é o atraso sináptico, enquanto, o quarto informa que a atividade de qualquer sinapse inibitória impede absolutamente a excitação do neurônio naquele momento e por fim o quinto que diz que a estrutura da rede de interconexão não muda com o tempo.

De acordo com Haykin (2001) esses modelos matemáticos “imitam” o cérebro humano de forma que o aprendizado de ambos é alcançado através do ambiente em um processo de aprendizagem que se dá por meio da força dos pesos sinápticos que no cérebro ocorre entre os neurônios, e nos sistemas, entre as redes.

Em mais uma definição, Lima e Labidi (1999) definem as RNAs como conjuntos bem estruturados de unidades de processamento que estão ligadas por canais de comunicação, onde cada um tem um determinado peso que equivale a um valor numérico. Essas estruturas são constituídas por neurônios (unidades de processamento) que ficam interligadas formando assim, uma estrutura de camadas e conexões entre as camadas.

## **2.6 Neurônio Artificial**

A formação de uma rede neural artificial consiste basicamente em neurônios e as conexões existentes entre eles. O neurônio é responsável por processar as informações e as conexões, que na verdade são os pesos sinápticos, ficam por conta do armazenamento das informações. Ademais, essas estruturas são responsáveis pela definição do efeito que a saída de um neurônio atua sobre a entrada do próximo neurônio. Neste sentido, salienta-se que conhecer alguns básicos sobre os

componentes e o funcionamento do cérebro humano são fundamentais para compreender a lógica por trás do funcionamento das redes neurais artificiais.

Similarmente ao biológico, o neurônio artificial, recebe um ou vários sinais de entrada e retorna um sinal de saída único. Este sinal de saída pode ser distribuído de duas formas: i) como único sinal de saída da rede; ii) como sinal de entrada para 1 ou vários neurônios da camada consecutiva. Mello, (2004) traz os pesos sinápticos, a função de ativação ou de transferência e a função de soma como os três elementos básicos de um neurônio artificial.

Dessa forma, fica claro que os pesos sinápticos, nada mais são que conexões entre os neurônios, conexões estas, responsáveis pelo armazenamento das informações e dentro deste panorama a função soma, se destaca por ser responsável por processar todos os estímulos responsáveis pelos respectivos pesos.

## **2.7 Estrutura das Redes Neurais Artificiais**

Em busca de simular por meio de modelos matemáticos o processamento de informações como ocorre no cérebro do ser humano, surgiram as redes neurais artificiais (HAIKIN, 2001; GRAUPE, 2013). Ambos os autores, reforçam que os neurônios artificiais em conjunto com as suas interconexões são os principais responsáveis pelo processamento das informações que são inseridas em um sistema, denominado redes neurais artificiais. Como já mencionado em outros tópicos, os neurônios são unidos por meio de conexões sinápticas, o que lhe atribui a capacidade de aprendizado (FREITAS, 2016).


Comumente, alguma regra de treinamento sempre é atribuída na grande parte dos modelos de redes neurais. Em síntese, neste processo os pesos das conexões dos neurônios são ajustados conforme os padrões apresentados, sendo assim, o aprendizado ocorre por meio de exemplos.

A arquitetura das redes neurais é organizada basicamente em camadas (Figura 1), onde pode haver conexões entre as unidades de cada camada, a quantidade de camadas vai variar de acordo com o modelo. Carpenter; Grossberg, (1987) classificaram essas camadas em três grupos, sendo a primeira a camada de entrada, onde os padrões ou as variáveis de entrada são apresentadas (os) a RNA, seguindo da camada intermediária, em que é feita grande parte do processamento da RNA, por

meio das conexões nela presente, e por fim a camada de saída, quando o resultado ou produto final é finalizado e apresentado.

Desta forma, percebemos que cada neurônio pode ter várias entradas, entretanto ao fim, somente uma saída. Além disso, cada saída também pode ser usada como variável de entrada por vários outros neurônios, isso ocorre por meio de ramificações. Portanto, um neurônio pode ser a porta de várias entradas advindas de outros neurônios. Segundo Widrow e Lehr (1990), cada conexão ou ligação entre neurônios detém de um peso, este peso é o que determina a contribuição da conexão na decisão de disparo, acarretando o controle dos estímulos.

**Figura 1.** Rede neural artificial.



Fonte: Widrow e Lehr (1990)

Quanto a estrutura, as redes neurais podem ser de dois tipos: as redes recorrentes em inglês "*feedback*" e não-recorrentes que são as "*feedforward*". As Redes Neurais Recorrentes possuem laços de realimentação, por isso são assim, definidas, ou seja, elas possuem contêm conexões de saída de uma camada determinada para servir de entrada da nesta mesma camada ou de camadas anteriores. De acordo com Freitas (2016), estas redes detêm de uma estrutura capaz de desenvolver nos neurônios internos uma memória em longo prazo.

Já as redes não-recorrentes, são caracterizadas por apresentarem uma estrutura disposta em camadas. Neste caso, cada camada recebe somente os sinais das camadas anteriores, ou seja, a redes não-recorrentes não apresentam lações de realimentação. Outra característica desta rede é o fato de não possuir memória, neste

caso, a sua saída é determinada conforme a entrada e os valores dos pesos (FREITAS, 2016).


Haikin (2001) ressalta que os pesos dados as conexões ajustadas no decorrer do aprendizado em conjunto com a arquitetura é o que diferenciam os tipos de redes neurais. Do mesmo modo que, o ambiente em que a rede está inserida é um fator primordial no processo de aprendizado da rede. Dito isto, compreende-se que afinal o que determina o aprendizado da RNA é a maneira como é feita a mudança dos parâmetros utilizados para compor o ambiente, em outras palavras, as variáveis de entrada.

## 2.8 Arquitetura de Redes Neurais Artificiais

### 2.8.1 Rede Linear (LNN)

A LNN é simples (Figura 2), sem camada ocultas e com uma e uma saída. Os pesos correspondem à matriz e os limites ao vetor de polarização. Quando a rede é executada, ela efetivamente multiplica a entrada pela matriz de pesos e adiciona o vetor de polarização.

**Figura 2.** Rede neural artificial – Linear.




Fonte: Di C, Yang X, Wang X (2014)

### 2.8.2 Rede Neural Perceptron Multicamadas (MLPNN)

A MLP (Figura 3) às vezes é chamada de rede “Back Propagation” (BP) é provavelmente a RNA mais popular em problemas de engenharia no caso de

mapeamento não linear e é chamada de “Aproximador universal” (KASHANINEJAD *et al.* 2009). É uma rede em camadas feed-forward que é composta pelas camadas de entrada, oculta e de saída.

**Figura 3.** Estrutura geral da rede neural MLP feed forward.




Fonte: Ghritlahre e Prasad (2018).

### 2.8.3 Rede Neural de Regressão Generalizada (GRNN)

Segundo Freitas (2016) rede neural GRNN (rede neural de regressão) possui um conceito diferente quando comparada a uma MLP, uma vez que é baseada em uma função de densidade de probabilidade (Figura 4). Possui quatro camadas, sendo uma de entrada, duas ocultas e uma de saída. A quantidade de neurônios em cada camada depende da quantidade de entradas, saídas e do conjunto de dados de treinamento. As GRNNs são um tipo de rede de base radial frequentemente usada para aproximação. A estrutura de um GRNN básico consiste em duas camadas. A primeira camada possui neurônios (base radial).

**Figura 4.** Estrutura básica do modelo GRNN.

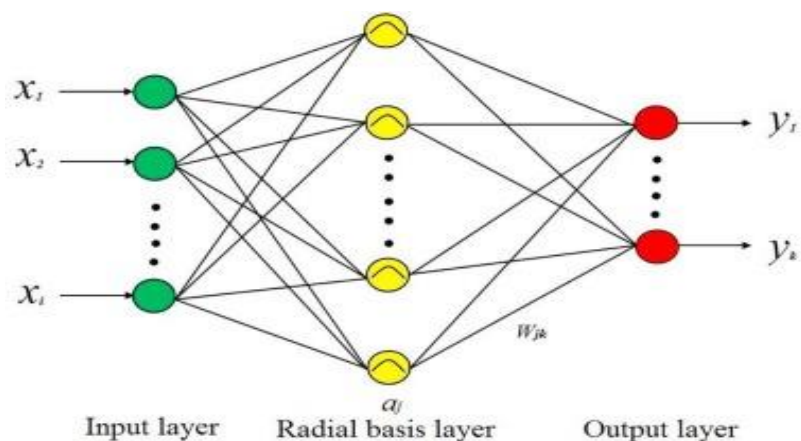


Fonte: Ghrilahre e Prasad (2018)

#### 2.8.4 Rede Neural Função de Base Radial (RBFNN)

Segundo Kashaninejad; Dehghani e Kashiri (2009) a RBFNN (Figura 5) têm uma base matemática muito forte, enraizada na teoria da regularização, para resolver problemas mal-condicionados. Geralmente consistem em três camadas: uma camada de entrada transparente, uma camada oculta com um número suficientemente grande de nós e uma camada de saída. Esta RNA é uma combinação linear de funções de base radial (TAKI *et al.* 2018).

**Figura 5.** Arquitetura do modelo RBFNN.



Fonte: Ghrilahre e Prasad (2018)

### 2.8.5 *Treinamento supervisionado e não supervisionado*

O treinamento de uma RNA é feito através de ajustes empregados aos seus pesos, caso o treinamento seja concluído com êxito, a RNA alcança uma solução universal para uma classe de problemas. Vários são os tipos de algoritmos utilizados em treinamentos de RNA e isso pode variar de acordo com os modelos de RNA. Estes modelos vão diferir pela forma como os pesos podem ser modificados, ou seja, o valor dado a cada peso. No universo de treinamento de RNA, as redes podem ser treinadas de duas formas, pelo modo de treinamento supervisionado ou não supervisionado. Estes dois aspectos são de suma importância, porque definem o modo como a RNA se relaciona com o ambiente (FREITAS, 2016).

Segundo Widrow e Lehr (1990), o treinamento supervisionado baseia-se no ajuste de pesos de uma rede neural que tem por objetivo gerar as saídas desejadas, levando sempre em consideração o conjunto de padrões de entrada. Em outras palavras, a rede recebe um conjunto de entradas já padronizado e com seus padrões de saída correspondente. O algoritmo “backpropagation” proposto em 1974 por Werbos é conhecido como um dos algoritmos de treinamento supervisionados com a mais ampla utilização.

No aprendizado supervisionado, como o próprio nome já sugere a rede neural é treinada com a ajuda de um supervisor. Sendo assim, as saídas obtidas ao final do treinamento deverão sempre ser conferidas, uma vez que, as saídas devem corroborar com os dados apresentados na entrada da rede. Se porventura, as saídas apresentarem diferentes do esperado, um reajuste dos pesos deve ser feito, de maneira que a rede seja capaz de armazenar melhor o conhecimento fornecido pelo meio. Tal processo deve ser refeito sempre com todo o conjunto de dados de treinamento, até que o acerto ou a saída esteja dentro do desejado.

O segundo tipo de treinamento, o não supervisionado, aplica-se quando não há a presença de um agente externo capaz de determinar a resposta desejada conforme os padrões dados na entrada. Dessa forma, o ajuste dos pesos da rede neural leva em consideração apenas o conjunto de padrões de entrada. Assim sendo, um método de treinamento denominado como auto supervisionado ou auto organizável, dado que, não há necessidade da saída desejada e da não obrigatoriedade de supervisores para realização do treinamento. Neste tipo de treinamento a rede neural trabalha as entradas e as organiza de modo que a classificação é feita por meio dos seus próprios

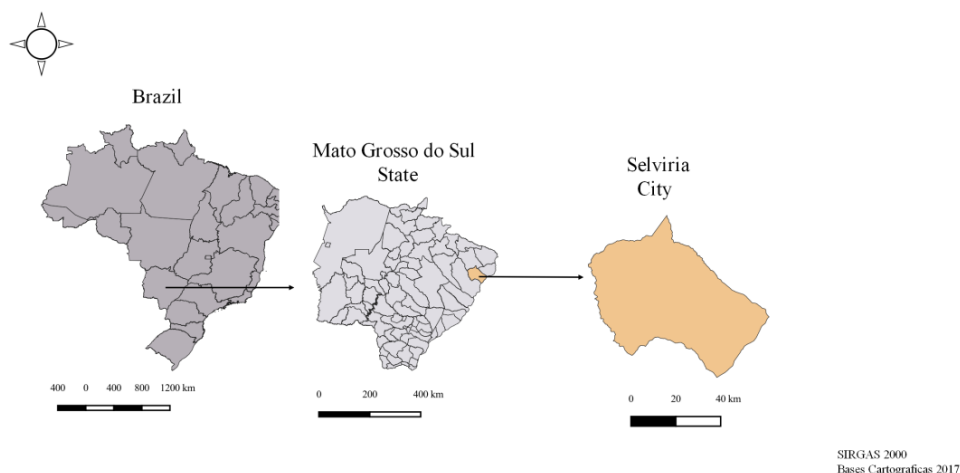
critérios. Nesse caso, os neurônios são utilizados como classificadores, sendo os dados de entrada os elementos de classificação. Por fim, a auto organização compila meios que envolve cooperação e a competição entre os neurônios da rede (FREITAS, 2016).

### 3 MATERIAL E MÉTODOS

#### 3.1 Área Experimental

Os estudos foram conduzidos em áreas de pastagem manejada (PM), pastagem degradada (PD) e sistema silvipastoril (SI) pertencentes à Fazenda de Ensino, Pesquisa e Extensão, da Faculdade de Engenharia, Campus de Ilha Solteira (UNESP), localizada no município de Selvíria-MS (Figura 6). As áreas de pastagem manejada e degradada estão localizadas nas coordenadas 20° 21' 58.2" S, 51° 24' 47.8" W e altitude 357 m, enquanto o sistema silvipastoril localiza-se nas coordenadas 20° 22' 31" de latitude Sul e 51° 24' 12" de longitude Oeste. O clima da região foi classificado como C1dAa' pelo sistema de Thornthwaite (ROLIM *et al.*, 2007), indicando uma região sub-úmido seco, sem excedentes hídricos, megatérmico com evapotranspiração no verão menor que 48% da evapotranspiração anual, temperatura média anual de 23,5 °C e precipitação pluvial média anual de 1.300 mm, com período de maior concentração entre os meses de novembro a abril, invernos secos de maio a setembro. O solo do sistema silvipastoril foi classificado conforme a Santos *et al.* (2018) Latossolo Vermelho distrófico típico argiloso com teor de argila na camada de 0,00-0,10 igual a 622,67 g kg<sup>-1</sup>, teor de areia igual a 213,42g kg<sup>-1</sup> e teor de silte igual a 163,91g kg<sup>-1</sup> determinados pelo método da pipeta (EMBRAPA 2017), A moderado (Haplic Acrustox), a geologia da área foi classificada como Basalto formação Serra Geral (MALTONI, 1994). Nas áreas de pastagens o solo foi classificado segundo Santos *et al.* (2018) como Latossolo Vermelho Distrófico com teor de argila na camada de 0,00- 0,10 m igual a 130 g kg<sup>-1</sup>, teor de silte igual a 60 g kg<sup>-1</sup> e teor de areia igual a 810 g kg<sup>-1</sup> determinados pelo método da pipeta (EMBRAPA, 2017) sendo a geologia classificada como Arenito formação Santo Anastácio (IBGE 2014).

**Figura 6.** Localização da área experimental em Selvíria, Mato Grosso do Sul, Brasil.




Fonte: Nogueira (2018)

As unidades experimentais de avaliação foram selecionadas de acordo com os usos da terra típicos da região, onde os processos envolvidos na mudança do uso e manejo ocorreram em áreas próximas, com o mesmo tipo de solo, do qual as variações de temperatura e regime de chuvas são semelhantes. As áreas possuíam solo recoberto por vegetação nativa do Cerrado até a década de 1970, sendo que no ano 1978 foram desmatadas e passaram a ser conduzidas com culturas anuais (milho, soja, algodão e adubos verdes) até o ano de 1986. Posteriormente, a área do sistema silvipastoril (SI) foi sendo formada a partir de essência florestal nativa, a Aroeira-vermelha (*Schinus terebinthifolius*) de ritmo lento de crescimento e para a formação da pastagem foi utilizado a espécie *Urochloa decumbens* (Figura 7C).

A área de pastagem degradada (PD) é constituída por espécie de *Urochloa decumbens* (syn. *Brachiaria decumbens*) há mais de 35 anos (Figura 7A), enquanto, a área de pastagem manejada (PM) é constituída por espécie de *Urochloa brizantha* (syn. *Brachiaria brizantha*), ambas as unidades experimentais conduzidas sem nenhum tipo de manejo do solo. Em 2014 ocorreu a introdução do sistema de rotação de culturas (*Urochloa brizantha* cv. *Marandu* e sorgo forrageiro) na área de PM (Figura 7B), no qual inicialmente foi realizada a correção do solo com posterior incorporação dos corretivos com grades, e adubação de base recomendada para a cultura do sorgo

forrageiro, em plantio concomitante *Urochloa brizantha* cv. *Marandu*. Aos 90 dias após emergência realizou-se a colheita do sorgo forrageiro para produção de silagem.

**Figura 7.** Aspectos gerais das áreas de pastagem degradada (A), pastagem manejada (B) e sistema silvipastoril (C) no Cerrado sul-matogrossense.



Fonte: Próprio Autor (2018)

### 3.2 Determinação da emissão de CO<sub>2</sub> do solo, temperatura e umidade do solo

A leitura da emissão de CO<sub>2</sub> do solo foi registrada por meio do sistema LI-COR (LI-8100), (Figura 8A). Em seu modo de medição, o sistema monitora as mudanças na concentração de CO<sub>2</sub> dentro da câmara (Figura 8B) por meio de espectroscopia na região do infravermelho. A câmara para solos apresenta volume interno de 854,2 cm<sup>3</sup> com área de contato circular de 83,7 cm<sup>2</sup>. Essa câmara foi acoplada sobre colares de PVC com dimensões de aproximadamente quatro polegadas de diâmetro e sete a oito cm de altura. Os anéis foram previamente inseridos no solo em cada um dos vinte pontos amostrais por manejo, na camada de 0,03 m, enquanto o restante do colar servia como base para o encaixe da câmara (0,04 a 0,05 m) do LI-8100. A concentração de CO<sub>2</sub> foi determinada a cada 1,0 segundo (em ppm), totalizando 1,0

minuto de análise em cada ponto amostral da área, ao passo que no final da leitura o equipamento calcula o valor do  $FCO_2$  ( $mmol\ m^{-2}\ s^{-1}$ ) por meio de um ajuste da concentração de  $CO_2$  do ar dentro da câmara em função de uma regressão parabólica no tempo.

Junto as leituras da  $FCO_2$  foram determinadas as avaliações da temperatura do solo ( $T_s$ ) com auxílio de um termômetro digital (Figura 9) e a umidade do solo ( $U_s$ ) que foi determinada por meio de um equipamento de TDR (Time Domain Reflectometry Hydrosense TM, Campbell Scientific, Austrália) (Figura 10); que consiste de duas hastes metálicas com 0,2 m inseridas perpendicularmente no solo. O mecanismo de funcionamento do TDR se dá através da medição do tempo médio necessário para um pulso eletromagnético ser percebido em um espaço de distância entre duas hastes, a partir disso o tempo é relacionado com a constante dielétrica média onde a sonda-guia foi inserida. Todas as leituras da  $FCO_2$ ,  $T_s$  e  $U_s$  foram realizadas entre as 7 e 10 horas da manhã, uma vez por semana no período de 05 de junho a 09 de julho de 2018 totalizando 35 dias de leituras, em 15 pontos amostrais nas áreas de estudo.

**Figura 8.** Sistema LI-8100 interligado à câmara de solos (A), e câmara para solo inserida sobre o colar de PVC (B).



Fonte: Próprio Autor (2018)

**Figura 9.** Termômetro medidor de temperatura do solo concomitante ao sistema LI-8100.



Fonte: Próprio Autor (2018)

**Figura 10.** TDR - Hydrosense system, sistema portátil utilizado para avaliação da umidade do solo.



Fonte: Próprio Autor (2018)

### 3.3 Amostragem e análise química do solo

Amostras de solo foram coletadas no final da avaliação da FCO<sub>2</sub>. Foram coletadas amostras deformadas de solo, nos 15 pontos amostrais com o auxílio de um trato holandês na profundidade de 0,00-0,10 m e secas o ar, antes de serem submetidas a qualquer tipo de análise. Após a secagem foram destorroadas e passadas em peneira de malha 2 mm. Para a caracterização química das amostras de solo foram realizadas as seguintes análises de rotina: potencial hidrogeniônico (pH), determinação do teor de matéria orgânica do solo (MO) P disponível (P), potássio (K<sup>+</sup>), Cálcio (Ca<sup>2+</sup>), Magnésio (Mg<sup>2+</sup>), soma de bases (SB), e acidez potencial (H+Al) (RAIJ *et al.*, 2001). Os teores de cálcio, magnésio e potássio trocáveis e fósforo

disponível foram extraídos utilizando-se o método da resina trocadora de íons (RAIJ, *et al.*, 2001); a capacidade de troca de cátions (CTC) e a saturação por bases (V%) também foram calculados, conforme Embrapa (1997). A suscetibilidade magnética (SM) foi determinada através da terra fina seca ao ar em baixa frequência (0,47 khz) utilizando o aparelho de bartington.

### **3.4 Processamento e análise de dados**

#### *3.4.1 Variabilidade temporal da emissão de CO<sub>2</sub>, temperatura e umidade do solo*

Os dados foram analisados, inicialmente, por meio da estatística descritiva (médio erro padrão da média, desvio-padrão, máximo, mínimo e coeficiente de variação, assimetria e curtose). Foi realizado o teste de Shapiro-Wilk, verificar a normalidade dos dados. Esses procedimentos realizados foram conduzidos no software R (R CORE TEAM, 2017). As variáveis foram analisadas por medidas repetidas no tempo, por meio de modelos mistos. Os dados foram avaliados pelo procedimento PROC MIXED do SAS (SAS versão 9.3, SAS instituto, Cary, NC, EUA). A comparação de médias foi realizada por meio do teste de Tukey, ao nível de significância de 5% de probabilidade. As análises de correlação linear entre as variáveis foram realizadas, utilizando o sistema SAS (SAS versão 9.3, SAS instituto, Cary, NC, EUA).

#### *3.4.2 Análise de componentes principais (ACP)*

A abordagem multivariada entre os atributos do solo foi estudada usando o pacote "factoextra" do software R. (R CORE TEAM, 2017). Os dados foram padronizados para (média nula e variância unitária), e, em seguida, submetidos à análise de componentes principais (PCA). Os principais componentes com eigenvalues  $\geq 1$ , e explicou variação de pelo menos 5% da variação total do conjunto de dados, examinados conforme Trevisan *et al.* (2017). A classificação dos eigenvectores, que são valores que representam o peso de cada atributo em cada componente (TREVISAN *et al.*, 2017), seguiu os seguintes critérios: valor absoluto  $< 0,30$ , indica pouco atributo significativo;  $0,30$  a  $0,50$  classifica o atributo como médio e;  $\geq 0,50$ , classificado como altamente significativo. Todos os atributos foram

encontrados com eigenvectores pesando mais ou igual a 0,50 - altamente significativo em alguns dos cinco PCs - portanto, estes foram mantidos na análise. Para uma melhor visão dos três primeiros PCs extraídos, foi criado um gráfico triplot mostrando a carga de cada atributo (setas) e as pontuações de cada tratamento (pontos).

### 3.4.3 *Redes neurais artificiais na predição da variabilidade espacial-temporal da emissão de CO<sub>2</sub> do solo.*

O conjunto de dados foi composto com as leituras da FCO<sub>2</sub>, Ts e Us compreendidos entre os dias de 05 de junho a 09 de julho de 2018. Totalizando 35 dias de leituras em 15 pontos observados em cada sistema agropecuário: pastagem degradada, pastagem manejada e sistemas silvipastoril. Em adição foram realizadas novas leituras da FCO<sub>2</sub>, Ts e Us nesses mesmos 15 pontos ocorridas entre os dias 01 de maio de 2019 a 30 de maio de 2019. Portanto, o conjunto de dados originais para a calibração das redes foi composto por 765 mensurações resultantes da FCO<sub>2</sub> observadas nos três sistemas agropecuários.

Para este estudo foram selecionados modelos de RNAs com quatro arquiteturas diferentes: Linear (LNN); regressão generalizada (GRNN), multilayer perceptrons (MPLNN) e de função de base radial (RBFNN) todas treinadas usando o programa Statistica7<sup>®</sup> StatSoft, Inc., EUA) no modo Intelligent Problem Solver (IPS). O aprendizado da rede foi supervisionado uma vez que o conjunto de valor do resultado esperado foi fornecido.

Foram construídos cenários com modelos individuais para cada uma das áreas de estudo (pastagem manejada; pastagem degradada; e sistema silvipastoril) e dois modelos globais (combinação das três áreas). Para o treinamento de cada cenário o IPS testou 100 diferentes configurações de RNAs e 05 foram selecionadas aleatoriamente pelo programa. O critério de parada e seleção utilizada pelo IPS são as redes com a menor raiz quadrada do erro médio (RMSE). Como estratégia de treinamento, 70% dos dados foram utilizados para treinamento e 30% para validação. Durante o treinamento das RNAs o IPS realizou uma análise de sensibilidade. A análise tem como objetivo diagnosticar a sensibilidade da rede em relação às variáveis e determinar a perda sofrida durante o processo de classificação, após o descarte de uma variável específica


### Cenário: 1. Modelo Global

Os dados originais foram compostos pelas 765 observações da  $FCO_2$  nos três sistemas agropecuários: pastagem manejada; pastagem degradada e sistema silvipastoril. As variáveis de entrada das RNAs (input) para estimar a  $FCO_2$  (output) foram: Ts; Us e atributos químicos (MOS; C; pH; H+Al; Al; P; Ca; Mg; K; SB; CTC) e SM.

### Cenário: 2. Global com Análise de Componentes Principais

Com o propósito de aperfeiçoar os modelos das RNAs, foram gerados novos modelos, no entanto, as variáveis de entrada das RNAs foram determinadas a partir de uma análise de componentes principais (ACP). Os dados originais da Ts, Us e dos atributos químicos (MOS; pH; H+Al; Al; P; Ca; Mg; K; SB; CTC) e SM dos três sistemas de manejo, foram determinados como os principais componentes: PC1, PC 2, PC 3, PC 4, PC 5, PC 6, PC 7, PC 8, PC 9, PC10, PC 11, PC 12 e PC 13, e utilizados como input das RNAs (Figura 11).

**Figura 11.** Arquitetura da rede neural – RBF- 14 neurônios na camada de entrada -39 camada intermediária e neurônio na camada de saída 1.



Fonte: autor (2019)

Cenários: 3 – Modelo individual para as áreas de pastagem manejada; pastagem degradada e sistema silvipastoril

Para cada sistema de manejo foi gerado novos modelos de RNAs (Tabelas 8, 8 e 9). Os dados originais foram compostos pelas 255 observações da FCO<sub>2</sub> correspondente ao tipo de manejo. As variáveis de entrada das RNAs (input) para estimar a FCO<sub>2</sub> (output) foram: Ts; Us e atributos químicos (MOS; C; pH; H+Al; Al; P; Ca; Mg; K; SB; CTC) e SM.

#### 3.4.4 Critérios de avaliação de desempenho das RNAs

O desempenho dos modelos foi avaliado por meio dos parâmetros estatísticos obtidos: Foi calculado o erro médio absoluto (MEA) (Eq. 1), raiz quadrada do erro médio (RMSE) (Eq. 2), coeficiente de correlação de Pearson (r) (Eq. 3), coeficiente de determinação (R<sup>2</sup>).

$$MEA = \frac{\sum_{i=1}^N (Y_{obs1} - Y_{est1})}{N} \quad (1)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Y_{obs1} - Y_{est1})^2}{N}} \quad (2)$$

$$r = \frac{(N \sum_{i=1}^N (X_{obs1} Y_{obs1}) - \sum_{i=1}^N X_{obs1} \sum_{i=1}^N Y_{obs1}) \left( (N \sum_{i=1}^N Y_{obs1})^2 - (\sum_{i=1}^N Y_{obs1})^2 \right)}{\sqrt{\left( (N \sum_{i=1}^N X_{obs1})^2 - (\sum_{i=1}^N X_{obs1})^2 \right)}} \quad (3)$$

Onde: A<sub>i</sub> = valor real; P<sub>i</sub> = valor previsto; N = número de dados; X<sub>obs<sub>i</sub></sub> = valores observados de X; Y<sub>obs<sub>i</sub></sub> = valores observados de Y;  $\bar{Y}$  = média observada de  $\bar{Y}$ .

## 4 RESULTADOS E DISCUSSÃO

#### 4.1 Variabilidade temporal da emissão de CO<sub>2</sub>, temperatura e umidade do solo

A estatística descritiva da emissão de CO<sub>2</sub> no solo, em áreas de PD, PM e sistema SI consta na Tabela 1. A maior média de emissão de CO<sub>2</sub> no solo foi verificada no sistema SI 1,562  $\mu\text{mol m}^{-2} \text{s}^{-1}$ , seguida pela intermediária observada no PD 1,215  $\mu\text{mol m}^{-2} \text{s}^{-1}$  e por último a observada no PM 0,973  $\mu\text{mol m}^{-2} \text{s}^{-1}$ , sendo que o intervalo de confiança a 95% de probabilidade corrobora essa afirmação, pois os limites inferiores e superiores não sobrepõem (Tabela 1).

Valores médios desvio padrão indicaram que a média de FCO<sub>2</sub> foi 60,82% foi maior no sistema SI (1,562  $\mu\text{mol m}^{-2} \text{s}^{-1}$ ) e significativamente diferente ( $p < 0,0001$ ), quando comparado à área de PR (0,973  $\mu\text{mol m}^{-2} \text{s}^{-1}$ ), e de 28,92% quando comparado à área de PD (1,215  $\mu\text{mol m}^{-2} \text{s}^{-1}$ ) durante o período de 35 dias de estudo. Verificou-se que a menor média de emissão de CO<sub>2</sub> foi obtida em área de PM (0,973  $\mu\text{mol m}^{-2} \text{s}^{-1}$ ). Figueiredo *et al.* (2016) ao estudar o FCO<sub>2</sub> e a suas correlações com os atributos do solo em pastagem manejada e degradada no estado de São Paulo, observaram médias de 5,96 e 8,73  $\mu\text{mol m}^{-2} \text{s}^{-1}$ , para pastagem manejada e degradada, respectivamente. Pode estar relacionado com o período de realização do experimento no inverno, justamente quando a pouca água no solo e as forragens se encontram secas e com baixo metabolismo e uma baixa atividade de microrganismos.

Ressaltaram-se ainda que as médias de emissão de CO<sub>2</sub> no sistema SI podem ser consideradas baixas, pois trabalhos relatam que as maiores médias de FCO<sub>2</sub> foram observadas na estação chuvosa (OLIVEIRA, 2018), e o presente estudo foi conduzido na estação seca. Este fato pode estar relacionado com a temperatura menos elevada e as precipitações pluviais menos recorrentes no período seco, e a profundidade das raízes das árvores do SI que alcançam maiores profundidades em busca de água e mantendo assim seu metabolismo e com isso liberando CO<sub>2</sub> pela respiração de suas raízes.

Os valores de coeficiente de variação (CV) nas áreas de PD, PM e sistema SI foram de 42,22%; 33,18% e 30,03%, respectivamente, sendo considerados altos (CV > 24%), segundo os critérios de classificação proposto por Warrick e Nielsen (1980) (Tabela 1).

A área de PD apresentou maior valor de CV, quando comparados à área de PM e sistema SI. Todavia, esse alto valor de CV encontrado em PD são similares àqueles observados em solos desprovidos de vegetação (LA SCALA JUNIOR *et al.*,

2000; FIGUEIREDO *et al.*, 2016; PANOSSO *et al.*, 2008; PANOSSO *et al.*, 2011a; TAVARES *et al.*, 2016) enquanto que menores valores de CV na área de PR e sistema SI podem estar relacionados a presença da palhada sobre a superfície do solo.

Além disso, os valores de médias nas áreas de PD, PM e SI não foram tão diferentes dos valores de mediana, indicando uma distribuição simétrica dos dados (Tabela 1). Os coeficientes de assimetria foram bastante próximos à zero, o que indica uma distribuição simétrica das observações para todos os sistemas avaliados.

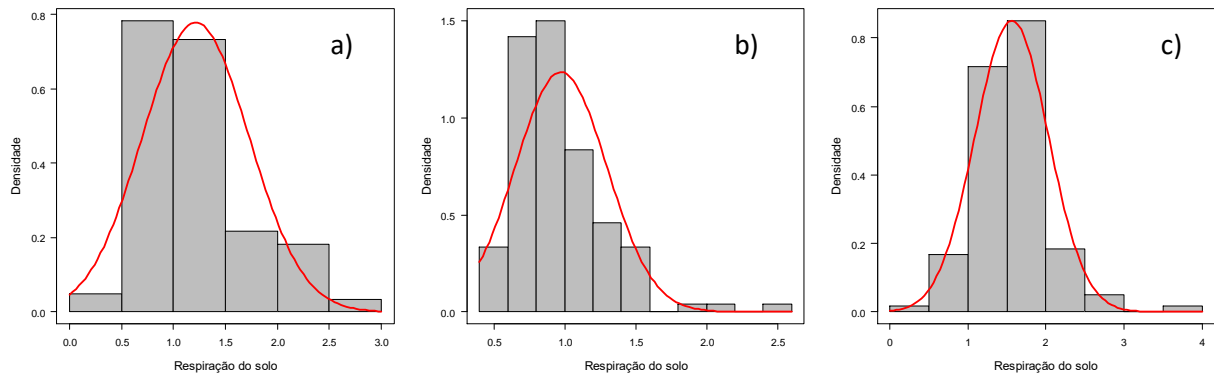
Quando se observa o teste de normalidade dos dados de Shapiro-Wilk, para os diferentes sistemas de manejo, a hipótese nula dos testes foi rejeitada ( $p < 0,0001$ ), e constata-se que os dados não apresentaram distribuição normal. Isso ocorreu principalmente devido à fuga das caudas das distribuições, observado pelos coeficientes de curtose maiores que zero no caso da área de PM e sistema SI. Contudo, apesar de não estarem completamente dentro da normalidade, não apresentaram uma fuga tão distante da mesma, evidenciado pela distribuição próxima à normal da figura 12 e pelos coeficientes de assimetria. Assim, optou-se pela não transformação dos dados e as demais análises estatísticas foram realizadas.

**Tabela 1.** Estatística descritiva da emissão de CO<sub>2</sub> do solo ( $\mu\text{mol m}^{-2} \text{s}^{-1}$ ).

Estatística	Sistema		
	Pasto degradado (PD)	Pasto manejado (PM)	Silvipastoril (SI)
Média	1,215	0,973	1,562
Mediana	1,105	0,920	1,550
Mínimo	0,270	0,490	0,300
Máximo	2,830	2,560	3,610
Desvio Padrão	0,513	0,323	0,469
Coeficientes			
CV(%)	42,228	33,188	30,030
Assimetria	0,932	1,735	0,779
Curtose	0,707	5,369	2,817
Intervalo de confiança (95%)			
Limite Inferior	1,122	0,915	1,478
Limite Superior	1,307	1,032	1,647
Teste de normalidade de Shapiro-Wilk			
Estatística w	0,940	0,880	0,950
P	<,0001	<,0001	<,0001

CV = coeficiente de variação. Fonte: Elaboração do próprio autor.

**Figura 12.** Histogramas da respiração do solo para as áreas de pastagem degradada (a), pastagem manejada (b) e sistema silvipastoril (c), durante o período de 35 dias de junho a julho de 2018.






Fonte: Próprio autor.

A análise de variância de medidas repetidas no tempo apresentou resposta significativa ( $p < 0,0001$ ) da interação entre os sistemas de manejo e o tempo (dias) para respiração, temperatura e umidade do solo (Tabela 2). As médias de respiração do solo e temperatura do solo no sistema SI foram superiores às áreas de PD e PM quando comparados, enquanto, as médias de Us apresentaram resultados inversos (Tabela 2).

A Figura 13 indica que a  $FCO_2$  e  $T_s$  foram maiores no sistema SI que nas áreas de PD e PR quando comparados, enquanto, a  $U_s$  se manteve mais elevada nas áreas PD e PR nos primeiros 10 dias de estudo, reduzindo com o passar do tempo. Esses valores médios de  $FCO_2$  coincidem com o dia em que a  $T_s$  atingiu seus máximos valores e a  $U_s$  os seus mínimos valores.

**Figura 13.** Variabilidade temporal da emissão de  $CO_2$ , temperatura e umidade do solo ao longo do período de 35 dias de estudo.



A partir do 11º dia, mesmo não havendo diferença significativa, é possível verificar decréscimo na emissão de CO<sub>2</sub>, enquanto, a Ts foi reduzida entre 11º e 17º dia, voltando a aumentar a partir desta data. Tal efeito pode ser associado ao fato de

que FCO<sub>2</sub> no SI ter maior sensibilidade por mudanças climáticos, como a ocorrência de chuvas pouco antes do período experimental.

Mudanças de FCO<sub>2</sub> após a precipitação uma maior sensibilidade de FCO<sub>2</sub> em relação a Us no sistema SI, em comparação às áreas PD e PM foram percebidas por meio das mudanças de FCO<sub>2</sub> após a precipitação. Essas variações de FCO<sub>2</sub> após a ocorrência de eventos de precipitação podem estar relacionadas às variações de outros atributos do solo, como, por exemplo, os teores de argila, os valores de biomassa microbiana, variações na granulometria da área e respiração radicular (XU; QI, 2001).

Na área de PM, constata-se que a respiração do solo reduziu nos períodos em que o solo apresentava maior umidade (até 10º dia) apresentada na Tabela 2, provavelmente devido à menor difusão de gás e taxa de produção de CO<sub>2</sub>. Fato esse, não observado no sistema SI, talvez pela quantidade de palhada e serapilheira e o tempo sob cultivo tenha influenciado a emissão de CO<sub>2</sub> no Silvipastoril.

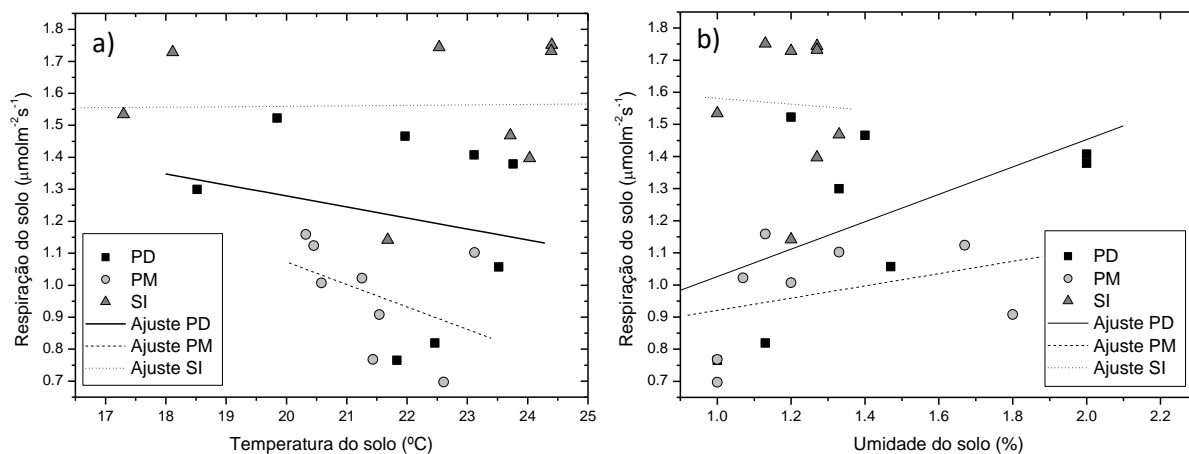
**Tabela 2.** Valores médios de respiração, temperatura e umidade do solo para todos os dias avaliados nas áreas de pastagem degradada (PD), pastagem manejada (PM) e sistema silvipastoril (SI).

Manejo	Dias de avaliação															
	1	2	10	11	17	22	30	35								
Respiração do solo ( $\mu\text{mol m}^{-2} \text{s}^{-1}$ )																
PD	1,41	b	1,47	a	1,38	b	1,52	a	1,30	b	1,06	b	0,82	b	0,77	b
PM	1,12	c	1,10	b	0,91	c	0,77	b	1,16	b	1,02	b	1,01	b	0,70	b
SI	1,75	a	1,74	a	1,73	a	1,53	a	1,43	a	1,40	a	1,47	a	1,14	a
Temperatura do solo (°C)																
PD	23,11	b	21,97	b	23,76	a	19,85	b	18,52	b	23,52	a	22,46	b	21,83	ab
PM	20,45	c	23,12	a	21,54	b	21,43	a	20,32	a	21,25	b	20,58	c	22,61	a
SI	24,40	a	22,53	ab	24,39	a	17,30	c	18,11	b	24,03	a	23,71	a	21,68	b
Umidade do solo (%)																
PD	2,00	a	1,40	a	2,00	a	1,20	a	1,33	a	1,47	a	1,13	a	1,00	a
PM	1,67	a	1,33	a	1,80	a	1,00	a	1,13	a	1,07	a	1,20	a	1,00	a
SI	1,13	b	1,27	a	1,27	a	1,00	a	1,20	a	1,27	a	1,33	a	1,20	b

Médias seguidas pelas mesmas letras nas colunas, não diferem entre si pelo teste de Tukey ao nível de 5% de significância.

Na figura 14 é possível observar a análise de regressão dos efeitos da Us e Ts sobre a respiração do solo nos diferentes sistemas de manejo. A área de PM apresentou redução linear na taxa de respiração do solo com o aumento da Ts (Figura 14b), enquanto, resultados inversos foram obtidos para Us (Figura 14a).


**Figura 14.** Relação linear da respiração do solo em função da temperatura (a) e umidade (b) do solo para cada manejo estudado durante o período de avaliação.



A respiração do solo é impulsionada principalmente pela decomposição microbiana de matéria orgânica do solo e raiz em respiração (ADUAN *et al.*, 2003; DAVIDSON; JANSSESNS, 2006), exsudados radiculares e serapilheira (RODEGHIRO *et al.*, 2013). O aumento da oxidação da atividade microbiana tem o potencial de liberar carbono orgânico adicional para atmosfera, contribuindo para a emissão de gases do efeito estufa (VICENTINI *et al.*, 2019). Na respiração aeróbia do solo, o  $\text{CO}_2$  é produzido e o  $\text{O}_2$  é consumido. Assim, a medida da respiração do solo é bastante variável e dependente, da disponibilidade do substrato e/ou palhada/serapilheira (no caso do estudo), umidade e temperatura do solo.

As emissões totais de  $\text{CO}_2$  para cada sistema de manejo, ao final do período de 35 dias de estudados, calculadas a partir das áreas abaixo das curvas de emissão, foram de 2,01, 1,52 e 1,27  $\text{Mg ha}^{-1}$  para SI, PM e PD, respectivamente (Figura 15). Portanto, um adicional médio de 0,62  $\text{Mg ha}^{-1}$  foi liberado para a atmosfera no SI, quando comparado às áreas de PD e PM. Apesar dessa ligeira diferença entre PD (1,52  $\text{Mg ha}^{-1}$ ) e PM (1,27  $\text{Mg ha}^{-1}$ ), não foi verificada diferença significativa pelo teste de Tukey à 5% de probabilidade. Contudo, o SI apresentou uma emissão total maior quando comparada às demais áreas (2,01  $\text{Mg ha}^{-1}$ ), o que equivale em média a ordem de 44% maior emissão de  $\text{CO}_2$  para essa área em relação ao PD e PM. Estando relacionado ao efeito da palhada mais o componente arbóreo, por possuir raízes profundas mantendo seu metabolismo.

**Figura 15.** Emissão total de CO<sub>2</sub> ao longo do período de 35 dias avaliados para as áreas de pasto degradado (PD), manejado (PM) e sistema silvipastoril (SI).



Médias seguidas pela mesma letra não diferem entre si pelo teste de Tukey à 5% de probabilidade.

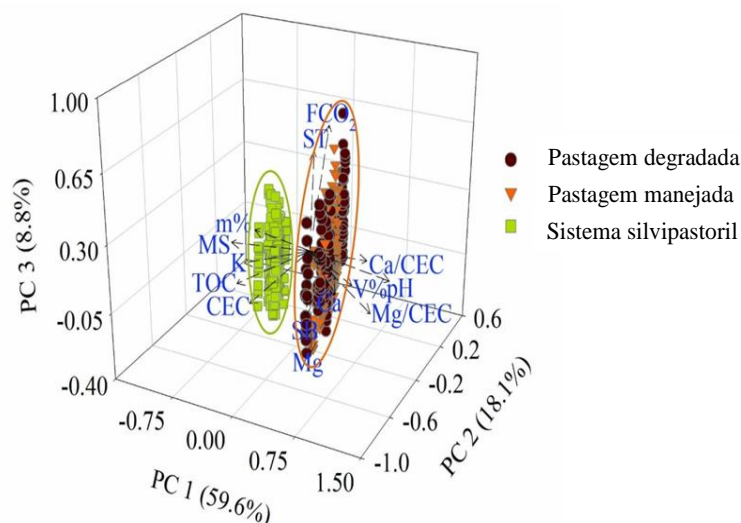
O estudo da variabilidade temporal da emissão de CO<sub>2</sub> do solo, proporciona informações importantes quanto a sua distribuição temporal, contribuindo na compreensão da dinâmica do CO<sub>2</sub> entre o solo e a atmosfera (XAVIER *et al.*, 2020), além de possibilitar a indicação de alternativas de sistema manejo que visam diminuir o efeito da variabilidade, resultando em uma agricultura eficiente, sustentável e rentável. (TEIXEIRA *et al.*, 2013).

#### 4.2 Análise de componentes principal da variabilidade espaço-temporal da emissão de CO<sub>2</sub> do solo

Na figura 16, encontra-se o gráfico triplot com os três primeiros componentes principais (PC). O componente principal 1 (PC1), principal 2 (PC2) e principal 3 (PC3) representaram a variância total dos dados originais em 59,6%, 18,1% e 8,8%, respectivamente. Deste modo, a análise como um todo foi capaz de a variância dos dados em 86,5%.

**Figura 16.** Gráfico da análise de componentes principais (PCA) com três dimensões mostrando os pesos dos sistemas de manejo (pontos), grupos (círculos) e atributos do solo (setas). Os pontos próximos correspondem as observações com pesos semelhantes nos componentes da PCA. O comprimento das setas indica a variação

dos atributos do solo nos componentes, enquanto os pontos indicam a correlação entre eles.



Subtítulo: emissão de CO<sub>2</sub> do solo (FCO<sub>2</sub>), temperatura do solo (ST), umidade do solo (SM), dias de calendário de leitura de CO<sub>2</sub> (TP), susceptibilidade magnética (MS), matéria orgânica do solo (SOM), carbono orgânico total (TOC), acidez potencial (H + Al), soma da base (SB), capacidade de troca catiônica (CEC), saturação de base (V%), porcentagem de Ca em CEC (Ca / CEC), porcentagem de Mg em CEC (Ca / CEC).

Ao observar o gráfico triplot é possível identificar a presença de dois grupos onde um se concentra os pontos que representam o sistema silvipastoril e no outro os sistemas de pastagem manejada e degradada. Em conjunto com SI, projetaram-se para a mesma direção os atributos m% (-0,943), SM (-0,937), K (-0,745), TOC (-0,755) e CEC (-0,832), sob direção oposta ficaram os atributos Ca (0,710), Ca/CEC (0,947), V% (0,985), pH (0,970) e Mg/CEC (0,890), o que demonstra uma relação inversa entre elas, todos esses atributos ficaram retidos em PC1, a componente de maior peso de acordo com a análise. A FCO<sub>2</sub> (0,795) projetou-se juntamente com ST (0,706) em PC3 dentro do agrupamento de PM e PD, enquanto isso Mg (-0,717) e SB (-0,801) ficaram retidas na PC2 (Tabela 3).

**Tabela 3.** Análise de fatores com três primeiros fatores e suas cargas fatoriais que com coeficientes de correlação entre os atributos do solo estudados.

Componente principal <sup>1</sup>	PC 1	PC 2	PC 3
	59,69	18,10	8,75
Atributos	Correlação <sup>2</sup>		
FCO <sub>2</sub>	0,180	-0,118	0,795*

ST	0,039	0,080	0,706*
SM	-0,937*	-0,308	0,036
TOC	-0,755*	-0,601*	-0,002
pH	0,970*	-0,094	0,039
K	-0,745*	-0,382	0,048
Ca	0,710*	-0,626*	0,080
Mg	0,536*	-0,717*	-0,192
SB	0,586*	-0,801*	0,006
CEC	-0,832*	-0,526*	-0,021
V%	0,985*	-0,120	-0,012
Ca/CTC	0,947*	-0,164	0,090
Mg/CTC	0,890*	0,041	-0,193
M%	-0,943*	-0,190	0,017

<sup>1</sup> PC: Componente principal. <sup>2</sup> \* indica variável correlacionada no componente principal

PD e PM apresentaram médias iguais para emissão total acumulada de CO<sub>2</sub> tal fato pode ter contribuído para que a FCO<sub>2</sub> ficasse retida nesse grupo. Tavanti *et al.*, (2020) ao avaliarem a FCO<sub>2</sub> sob pastagem sem manejo e manejada encontraram por meio de correlação canônica a FCO<sub>2</sub> retida no grupo da pastagem sem manejo.

Correlação positiva com a temperatura do solo, deve-se principalmente ao fato da temperatura contribuir para o aumento da atividade microbiana do solo, que tem como produto o CO<sub>2</sub> (LUO E ZHOU, 2006). Trabalhos realizados por Moitinho *et al.*, (2018) e Panosso *et al.*, (2011a) sob áreas de cultivo de cana de açúcar também observaram essa relação da FCO<sub>2</sub> com Ts ao realizarem análise de componentes principais.

Estudos focados em observar as perdas de carbono do solo devido o aquecimento, tem relevado resultados interessantes. Nottingham *et al.*, (2020) por exemplo, observaram que após dois anos de aquecimento de todo o perfil do solo em quatro graus Celsius as emissões de CO<sub>2</sub> aumentaram em 55% em comparação a solos que não foram submetidos ao aquecimento sob condições de florestas tropicais. Pries *et al.* (2017) em estudo semelhante, observaram que a produção de CO<sub>2</sub> aumenta em todas as profundidades quando o solo é submetido ao aquecimento de 4°C, demonstrando que todas as profundidades do solo respondem ao aquecimento e que essa sensibilidade impulsiona a decomposição do carbono armazenado no solo,

o que resultou em um aumento anual de 34 a 37% de perdas de carbono para atmosfera.

A retenção de muitos atributos relacionados a fertilidade do solo no mesmo grupo do SI pode ter relação ao material de origem do solo da área. Em SI o solo tem como material de origem o Basalto, enquanto PD e PM o Arenito. Tal fato, confere a SI um solo bastante rico em argila, com diferença considerável ao se comparar com PD e PM. SI apresenta 622,67 g kg<sup>-1</sup> de argila na camada 0,00 - 0,10 m enquanto PM e PD apresenta somente 130 g kg<sup>-1</sup> de argila para mesma camada, comportamento inverso é observado para a quantidade de areia (OLIVEIRA, 2018; TAVANTI *et al.*, 2020).

Diversos estudos demonstram que solos de origem basáltica são solos mais férteis (ALMEIDA *et al.*, 2018; MEIRELES *et al.*, 2012), isso graças aos altos teores de argila. Em solos argilosos costumam apresentar maior quantidade de matéria orgânica, principalmente sob presença de cultivo de gramíneas ou de sistemas agrícolas que não revolvem o solo (SANTOS *et al.*, 2019). Dematê e colaboradores (2003) reforçam que em solos argilosos, como o Latossolo Vermelho Eutroférico e Nitossolo Vermelho, a fração argila reage com a matéria orgânica o que traz estabilidade na formação de compostos argilo-húmicos, enquanto, em solos mais arenosos, como o Argissolo Vermelho-Amarelo e Neossolo Quartzarênico, a matéria orgânica acaba protegendo as frações mais grosseira, ou seja, com pouca estabilidade. Esses compostos argilo-húmicos são essenciais para manutenção da saúde do solo. Dessa forma entendemos que, a matéria orgânica é uma das principais portas de entrada para manutenção da saúde e da fertilidade do solo.

Neste sentido, é importante salientar que ao avaliar a sustentabilidade de um agroecossistema como um todo, vários aspectos devem ser levados em consideração. Nesse estudo, ao avaliar três agroecossistemas diferentes onde todos estão instalados sob as mesmas condições ambientais e em latossolos vermelho, a origem do material do solo acabou por explicar alguns resultados.

### 4.3 Redes Neurais Artificiais na predição da variabilidade espaço- temporal da emissão de CO<sub>2</sub> do solo

A Tabela 4 apresenta os índices estatísticos para as 5 redes obtidas no modelo global. do primeiro cenário. A MLPNN e a LNN na fase de calibração apresentaram os menores valores de RMSE, com variação entre 0,130 a 0,136  $\mu\text{mol m}^{-2}\text{s}^{-1}$ ; quando comparados com o modelo GRNN e MLPNN. Para as RBFNN e GRNN os valores variaram de 0,789 a 0,800  $\mu\text{mol m}^{-2}$ , respectivamente. Variação similar ocorreu em todas as RNAs na fase de validação.

E o índice erro médio absoluto apresentaram pouca variação durante a fase de validação quanto a precisão dos modelos, todos mostraram correlação superior a ( $r = 0,50$ ) e os valores de desvio padrão foram menores que 1. Com base no coeficiente de determinação na fase de validação os melhores modelos observados foram para a LNN, GRNN e RBF.

**Tabela 4.** Cenário 1: Modelo Global. Resumo das análises estatísticas realizadas para os vários modelos de redes neurais artificiais (RNAs).

RNA	Arquitetura	Calibração RMSE	Validação RMSE	Validação MEA	Ds_Padrão	r	R <sup>2</sup> . aj
1	GRNN 16:16-379-2-1:1	0,800	0,867	0,647	0,837	0,56	0,31
2	RBF 16:16-39-1:1	0,789	0,833	0,641	0,824	0,57	0,32
3	MLP 9:9-6-1:1	0,131	0,134	0,644	0,840	0,54	0,29
4	MLP 10:10-11-4-1:1	0,136	0,132	0,661	0,862	0,51	0,26
5	Linear 15:15-1:1	0,130	0,132	0,642	0,831	0,56	0,31

Arquitetura: sequência de números indica o número de variáveis de entradas, n<sup>o</sup> de neurônios na primeira camada e n<sup>o</sup> de neurônios na segunda camada, respectivamente; RMSE: erro quadrático médio da raiz; MEA: erro médio absoluto; Ds Padrão: desvio padrão da fase validação; r: correlação de Pearson da fase de validação; R<sup>2</sup>.aj: Coeficiente de determinação ajustado na fase de validação.

No modelo global proposto pelo segundo cenário (Tabela 5) verificou-se que quando as variáveis de entrada das RNAs foram as componentes principais (Tabela 6), todos os modelos exibiram correlação superior a (0,67) (Tabela 5) Nos modelos na fase de calibração os valores de RMSE foram inferiores aos estudados no cenário 1. A MLPNN e LNN apresentaram os menores valores de RMSE nas fases de calibração e validação, destacando-se a RNA cinco, que exibiu os menores valores de RMSE na calibração e validação (0,124; 0,143  $\mu\text{mol m}^{-2}$ ). Os maiores valores foram observados na GRNN (0,726; 0,843) para ambas as fases calibração e validação respectivamente.

Nesse cenário o menor erro médio absoluto foi e o menor observado na RBFNN (0,493) e o maior na MLPNN (0,712) com menor número de neurônios (RNA3), A RBFNN apresentou o melhor resultado quanto a precisão, com maior valor de  $r$  (0,74) e menor valor de desvio padrão (0,66) e MEA (0,49  $\mu\text{mol m}^{-2} \text{s}^{-1}$ ).

**Tabela 5.** Cenário 2: Modelo Global com análise de componentes principal. Resumo das análises estatísticas realizadas para os vários modelos de redes neurais artificiais (RNAs).

RNA	Arquitetura	Calibração RMSE	Validação RMSE	Validação MEA	Ds_Padrão	r	R <sup>2</sup> . aj
1	GRNN 14:14-379-2-1:1	0,726	0,843	0,609	0,77	0,67	0,45
2	RBF 14:14-39-1:1	0,599	0,746	0,493	0,66	0,75	0,56
3	MLP 3:3-5-1:1	0,135	0,149	0,712	0,71	0,70	0,49
4	Linear 13:13-1:1	0,130	0,148	0,525	0,70	0,71	0,51
5	MLP 10:10-6-1:1	0,124	0,143	0,502	0,68	0,73	0,54

Arquitetura: sequência de números indica o número de variáveis de entradas, n<sup>o</sup> de neurônios na primeira camada e n<sup>o</sup> de neurônios na segunda camada, respectivamente; RMSE: erro quadrático médio da raiz; MEA: erro médio absoluto; Ds\_Padrão: desvio padrão da fase validação; r: correlação de Pearson da fase de validação; R<sup>2</sup>.aj: Coeficiente de determinação ajustado na fase de validação.

Na ACP1 as maiores correlações foram observadas para os atributos químicos do solo de SM, MO, C, K, H+ Al, Al e CTC, enquanto, na ACP2 destacaram-se a SB e Mg, e na ACP3 a Ts (Tabela 6). Os atributos químicos do solo, tais como pH, H+Al, Al e CTC apresentaram correlação entre (0,90) e (0,98) enquanto, a Us, M.O, CO e K apresentaram correlação entre 0,80 e 0,89 todas as variáveis supracitadas podem ser analisadas a partir do ACP1.

Na ACP2 apenas as variáveis teores de Ca (0,77), Mg (0,81) e SB (0,90) apresentaram correlação significativas para análise, enquanto, na ACP3 somente com a Ts (0,76). De acordo com Jolliffe (1972) as principais CPs são aquelas com correlação maior que 0,7 o que garante uma reprodução da variabilidade significativa. As demais ACPs não selecionadas (ACP4, ACP5, ACP6, ACP7, ACP8, ACP9, ACP10, ACP11, ACP12 e ACP13) expressaram quase que em sua totalidade baixas correlações. Assim, com a seleção das principais CPs, o conjunto de dados com treze variáveis sintéticas (CPs) e 765 mensurações foi reduzido a três variáveis sintéticas (ACPs).

**Tabela 6.** Coordenadas fatoriais das variáveis, baseadas nas correlações corresponde ao modelo global do cenário 2.

	CP1	CP2	CP3	CP 4	CP 5	CP 6	CP 7	CP8	CP9	CP10	CP11	CP12	CP13
Área	0,88	-0,10	-0,08	0,11	-0,04	-0,10	0,02	-0,21	-0,36	0,10	0,00	-0,01	-0,01
Ts	-0,11	-0,08	0,76	0,12	0,62	-0,01	0,04	-0,03	-0,03	0,00	0,00	0,00	0,00
Us	0,84	-0,10	0,17	0,01	-0,02	0,17	-0,46	0,13	-0,05	0,01	0,00	0,00	0,00
SM	0,98	-0,08	0,03	0,01	-0,01	-0,06	0,04	0,05	-0,03	-0,01	-0,02	0,12	0,03
P	-0,24	-0,37	-0,20	0,87	0,00	0,02	-0,04	-0,06	0,10	0,01	-0,02	0,00	0,00
MO	0,88	-0,41	0,01	-0,11	0,02	-0,03	0,03	-0,04	0,18	0,12	0,01	-0,01	0,00
CO(	0,88	-0,41	0,01	-0,11	0,02	-0,03	0,03	-0,04	0,18	0,12	0,01	-0,01	0,00
pH	-0,92	-0,31	0,05	-0,12	-0,03	0,04	0,01	0,08	-0,05	0,09	-0,17	-0,01	0,01
K	0,81	-0,18	0,05	0,02	-0,06	0,51	0,20	0,01	-0,05	-0,03	-0,01	0,00	-0,01
Ca	-0,56	-0,77	0,02	0,03	-0,05	-0,10	0,05	0,25	-0,10	0,02	0,06	0,00	0,00
Mg	-0,34	-0,81	-0,16	-0,26	0,11	0,01	-0,12	-0,30	0,04	-0,11	-0,02	0,02	-0,01
H+Al	0,99	-0,04	0,02	0,03	0,00	-0,09	0,04	0,07	0,04	-0,07	-0,04	-0,03	0,04
Al	0,97	-0,01	0,01	0,04	0,01	-0,19	0,04	0,11	0,01	-0,07	-0,06	0,00	-0,08
SB	-0,39	-0,91	-0,03	-0,06	-0,01	0,03	0,04	0,09	-0,07	-0,03	0,04	0,01	-0,01
CTC	0,93	-0,32	-0,05	0,02	0,02	-0,09	0,03	0,03	-0,03	-0,10	-0,01	-0,06	0,04

Ts - Temperatura do solo (%), Us - Umidade do solo (%), SM - Suceptibilidade magnética, P - fosforo (mg/dm<sup>3</sup>), MO - matéria orgânica (g/dm<sup>3</sup>), C - carbono (g/dm<sup>3</sup>), K - potássio (mmolc/dm<sup>3</sup>), Ca- cálcio (mmolc/dm<sup>3</sup>), Mg - magnésio (mmolc/dm<sup>3</sup>), H+Al ; mmolc/dm<sup>3</sup>Al - alumínio mmolc/dm<sup>3</sup>, SB- soma de bases (mmolc/dm<sup>3</sup>), CTC - capacidade de troca de cátions (mmolc/dm<sup>3</sup>).

Ao analisarmos os modelos individuais na área de pastagens degradadas. (Tabela 7), nota-se que todas as RNAs tiveram bons resultados de correlação na fase de validação com valor superior a ( $r = 0,83$ ). Os desvios padrão para todos os modelos foram semelhantes.

Os menores valores de RMSE na fase de calibração foram observados na MLPNN e LNN (0,152 e 0,160  $\mu\text{mol m}^{-2} \text{s}^{-1}$ ) respectivamente e o maior na RBFNN com valor de 0,663  $\mu\text{mol m}^{-2} \text{s}^{-1}$ . Na fase de calibração as RNAs mantiveram o mesmo padrão, com menores valores na LNN e MLPNN e maiores nas GRNN e RBFNN. Pelo coeficiente de determinação ajustado na fase de validação o melhor modelo na predição da emissão FCO<sub>2</sub> nas áreas degradada foi a RNA 5 (MLP 9:9-13-8-1:1) que também exibiu o menor erro médio absoluto (0,396  $\mu\text{mol m}^{-2} \text{s}^{-1}$ ) quando comparada com os demais modelos.

**Tabela 7.** Pastagem degradada (PD). Resumo das análises estatísticas realizadas para os vários modelos de redes neurais artificiais (RNAs).

RNA	Arquitetura	Calibração RMSE	Validação RMSE	MEA	Ds_Padrão	r	R <sup>2</sup> <sub>aj</sub>
1	GRNN 12:12-125-2-1:1	0,413	0,663	0,393	0,556	0,83	0,69
2	RBF 10:10-17-1:1	0,518	0,656	0,424	0,556	0,83	0,69
3	Linear 12:12-1:1	0,110	0,160	0,408	0,553	0,84	0,70
4	MLP 9:9-13-8-1:1	0,116	0,155	0,415	0,557	0,83	0,69
5	MLP 11:11-7-1:1	0,108	0,152	0,396	0,541	0,84	0,71

Arquitetura: sequência de números indica o número de variáveis de entradas, nº de neurônios na primeira camada e nº de neurônios na segunda camada, respectivamente; RMSE: erro quadrático médio da raiz; MEA: erro médio absoluto; Ds\_Padrão: desvio padrão da fase validação; r: correlação de Pearson da fase de validação; R<sup>2</sup>.aj: Coeficiente de determinação ajustado na fase de validação.

Na área de pastagens manejada à fase de calibração das RNAs apresentaram valores de RMSE que variaram de 0,146 a 0,906  $\mu\text{mol m}^{-2} \text{s}^{-1}$ . A melhor acurácia observada pelo RMSE tanto na fase de calibração quanto na fase de validação foram para as MLPNN bem como os menores valores de desvio padrão e maiores precisão ( $r = 0,63$ ) e R<sup>2</sup> 0,39 (Tabela 8). Para Freitas (2016), que analisaram variabilidade espacial da FCO<sub>2</sub> em áreas de cana-de-açúcar, usando uma rede neural MLP composta por três camadas, 7, 18 e 1 neurônios, respectivamente, com o algoritmo de retropropagação e o método foi altamente eficaz explicando R<sup>2</sup> 80% do fluxo espacial.

**Tabela 8.** Pastagem Manejada (PM). Resumo das análises estatísticas realizadas para os vários modelos de redes neurais artificiais (RNAs).

RNA	Arquitetura	Calibração RMSE	Validação RMSE	MAE	Desvio Padrão	r	R <sup>2</sup> , aj
1	GRNN 14:14-129-2-1:1	0,907	0,943	0,843	0,970	0,26	0,06
2	RBF 14:14-18-1:1	0,768	0,796	0,680	0,819	0,58	0,33
3	Linear 13:13-1:1	0,207	0,207	0,831	0,942	0,34	0,11
4	MLP 13:13-9-1:1	0,146	0,200	0,645	0,785	0,63	0,40
5	MLP 10:10-13-4-1:1	0,156	0,189	0,636	0,781	0,63	0,40

Arquitetura: sequência de números indica o número de variáveis de entradas, nº de neurônios na primeira camada e nº de neurônios na segunda camada, respectivamente; RMSE: erro quadrático médio da raiz; MEA: erro médio absoluto; Ds\_Padrão: desvio padrão da fase validação; r: correlação de Pearson da fase de validação; R<sup>2</sup>.aj: Coeficiente de determinação ajustado na fase de validação.

No sistema Silvipastoril, percebe-se que todos os modelos exibiram uma baixa precisão e o maior valor do coeficiente de determinação foi observado na GRNN (R<sup>2</sup> = 20). Os modelos LNN e MLPNN observados nas obtiveram melhor acurácia com RMSE na calibração de (0,183; 0,186 e 0,188  $\mu\text{mol m}^{-2} \text{s}^{-1}$ ) e validação (0,203; 0,208 e 0,213  $\mu\text{mol m}^{-2} \text{s}^{-1}$ ) respectivamente.

Segundo Braga *et al.* (2000) definir a quantidade ideal de neurônios na camada oculta é extremamente importante e das RNAs afeta a precisão dos modelos. No entanto, no presente estudo a complexidade das RNAs com maior número de neurônios na camada oculta não influenciou na predição na FCO<sub>2</sub>. Modelar FCO<sub>2</sub> é uma tarefa complexa, uma vez que, ela é o resultado de diversos processos bioquímicos no solo e está relacionado a respiração das raízes (LAL, 2009). Os atributos químicos do solo e físicos do solo estão relacionados aos processos de produção e transporte da FCO<sub>2</sub> (MOITINHO *et al.*, 2015, XAVIER *et al.*, 2019). No presente estudo foram usadas apenas variáveis vinculadas às propriedades químicas do solo. Segundo Bernadino (2007), o sistema Silvistoril é um modo de utilização do solo muito mais complexo que os demais. Provavelmente o microclima formado pelas árvores influenciam na dinâmica das trocas gasosas no solo.

**Tabela 9.** Sistemas Silvistoril (SI). Resumo das análises estatísticas realizadas para os vários modelos de redes neurais artificiais (RNAs).

RNA	Arquitetura	Calibração RMSE	Validação RMSE	MAE	Ds_Padrão	r	R <sup>2</sup> , aj
1	RBF 14:14-17-1:1	0,830	1,005	0,702	0,911	0,44	0,19
2	GRNN 14:14-120-2-1:1	0,859	0,975	0,676	0,895	0,45	0,20
3	Linear 13:13-1:1		0,213	0,683	0,906	0,42	0,18
4	MLP 6:6-13-9-1:1	0,188	0,208	0,689	0,908	0,42	0,17
5	MLP 8:8-8-1:1	0,186	0,203	0,694	0,903	0,43	0,18

Arquitetura: sequência de números indica o número de variáveis de entradas, n<sup>o</sup> de neurônios na primeira camada e n<sup>o</sup> de neurônios na segunda camada, respectivamente; RMSE: erro quadrático médio da raiz; MEA: erro médio absoluto; Ds\_Padrão: desvio padrão da fase validação; r: correlação de Pearson da fase de validação; R<sup>2</sup>.aj: Coeficiente de determinação ajustado na fase de validação.

O IPS forneceu a análise de sensibilidade como parte dos resultados da simulação de rede neural. E, pela análise de sensibilidade foi possível verificar quais variáveis de entrada são as preditoras mais importantes, conforme descrito por (HUNTER *et al.*, 2000). As variáveis foram classificadas em ordem de importância. Pela análise de sensibilidade, conforme apresentado na Tabela 10. No primeiro cenário global estudado as variáveis que mais influenciaram a RNA 1 (GRNN 16:16-379-2-1:1) foram: tipo de manejo do solo (Área), a CTC e o teor de matéria orgânica foram as três variáveis que mais influenciaram esse modelo. E na RNA 5 (LNN 15:15-1:1) a soma de bases, Ca e o Mg foram as variáveis que mais contribuíram. A CTC do solo como atributo químico do solo, de certa forma é influenciada teores de MO, que

promove a ciclagem de nutrientes e contribui para a manutenção dos agregados do solo, bem como para a manutenção da sua umidade (ROSCOE *et al.*, 2006). Segundo Duah-Yentumi *et al.* (1998) e a baixa disponibilidade desses macronutrientes pode comprometer o crescimento microbiano e conseqüentemente a taxa de respiração do solo.

Diante do exposto, nota-se que a matéria orgânica é a principal fonte de C para os microrganismos. E, partindo destas observações, neste estudo, a FCO<sub>2</sub> e a MOS foram positivamente correlacionadas com a CTC, uma vez que contribui para o incremento da fertilidade desses solos. Segundo Resck (1998), a fertilidade do solo contribui com a atividade microbiana e conseqüentemente com a produção de CO<sub>2</sub>. Em estudos conduzidos em latossolos La Scala *et al.* (2000), Santos *et al.* (2019) e Xavier *et al.* (2019) observaram que a FCO<sub>2</sub> foi influenciada pela CTC do solo, carbono total e pelos teores de teor de óxidos de ferro (Fe) e a precipitação. No entanto os autores não encontraram correlações lineares entre a FCO<sub>2</sub> e os demais atributos do solo como pH e saturação por bases.

De uma forma geral nas áreas de pastagem degradada a Ts e A Us foram as variáveis que mais influenciaram todos os modelos. O fluxo de CO<sub>2</sub> está relacionado com a umidade e os atributos químicos do solo; por outro lado, a temperatura do solo foi o fator mais importante referente à variação temporal da respiração do solo. Os teores de Ca, Mg, acidez potencial (H+Al) e matéria orgânica (M.O) são nulos na maioria das redes e conseqüentemente efeitos na Ts e Us são constatadas. No entanto, para RNA 5 (MLP 11:11-7-1:1) além da temperatura do solo os teores de Al e Mg foram que mais contribuíram com essa rede.

Para a área de pastagem manejada as melhores RNAs (MLP 13:13-9-1:1 e MLP 10:10-13-4-1:1) a CTC, Ca, H+Al e MO foram as variáveis que mais contribuíram com esses modelos. Em pastagens manejadas os teores dos nutrientes supracitados foram superiores, o que permite a correlação do calcário com a capacidade de neutralização da acidez do solo e aumento da disponibilidade de nutrientes ao sistema radicular das plantas, melhorando seu desenvolvimento e, conseqüentemente, aumentando os teores de matéria orgânica do solo e, por conseguinte retenção de Us e atividade microbiológica. Na área de sistema silvipastoril de uma forma geral a SB, a CTC, Ca e Mg foram as variáveis com maiores contribuições nos modelos para ajudar a estimar a FCO<sub>2</sub>.

**Tabela 10.** Análise de Sensibilidade com classificação dos atributos do solo (programa Statistica7® no modo Intelligent Problem Solver (IPS)).

Modelo Global Cenário 1															
	Area	Ts(%)	Us(%)	SM	P (mg/dm <sup>3</sup> )	MO	C	pH	K	Ca	Mg	H+Al	Al	SB	CTC
RNA 1	1	6	9	14	12	3	4	8	16	7	5	13	11	10	2
RNA 2	6	14	1	4	13	8	9	10	12	11	3	5	7	15	2
RNA 3	4	8		5		7	9			6		2	9	3	1
RNA 4	6	-			10			5	8	2	7	3	4		1
RNA 5	10	13	11	9	15	6	5	14	4	2	3	7	12	1	8
Pastagem Degradada															
	Ts(%)	Us(%)	SM	P (mg/dm <sup>3</sup> )	MO	pH	K	Ca	Mg	H+Al	Al	SB	CTC		
RNA 1	1	3	5	6		9	4				2	8	7		
RNA 2	1	2	13	3	6	5	4	10	7	11	12	9	8		
RNA 3		8	11	10	7	9	6	3	5	4	12	1	2		
RNA 4	1	2	8		4	6		9		7	5	3			
RNA5	1	2		7	6		9		3	5	4	8			
Pastagem Manejada															
	Ts(%)	Us(%)	SM	P (mg/dm <sup>3</sup> )	MO	pH	K	Ca	Mg	H+Al	Al	CTC			
RNA 1	3	4	12	1	11	6	10	2	7	5	8	9			
RNA 2	6	2		10	5	7		1	3	8	9	4			
RNA 3	8	9	12	10	4	3	11	2	7	5	6	1			
RNA 4	7				3	5	8	2	9	4	6	1			
RNA 5	7	8		9	4	5	10	2	11	3	6	1			
Silvipastoril															
	Ts(%)	Us(%)	SM	P (mg/dm <sup>3</sup> )	MO	C	pH	K	Ca	Mg	H+Al	Al	SB	CTC	
RNA 1	14	9	3	8	6	7	2	5	1	11	12	13	4	10	
RNA 2	3	13	1	14	9	10	6	5	4	8	11	12	2	7	
RNA 3	12		11	9	5	4	13	6	8	7	1	10	3	2	
RNA 4	5			4		6	3						1	2	
RNA 5	5				6	7	8		2	3		4	1		

Ts - Temperatura do solo (%), Us – Umidade do solo (%), SM – Suceptibilidade magnética, P – fósforo (mg/dm<sup>3</sup>), MO – matéria orgânica (g/dm<sup>3</sup>), C – carbono (g/dm<sup>3</sup>), K – potássio (mmolc/dm<sup>3</sup>), Ca- cálcio (mmolc/dm<sup>3</sup>), Mg – magnésio (mmolc/dm<sup>3</sup>), H+Al ; mmolc/dm<sup>3</sup>Al – alumínio mmolc/dm<sup>3</sup>, SB- soma de bases (mmolc/dm<sup>3</sup>), CTC – capacidade de troca de cátions (mmolc/dm<sup>3</sup>).

## 5 CONCLUSÕES

A variação da temperatura e umidade do solo interferem nas emissões de CO<sub>2</sub> do solo ao longo do tempo. No período de inverno, a menor média de emissão de CO<sub>2</sub> foi obtida em área de pastagem manejada (0,973  $\mu\text{mol m}^{-2} \text{s}^{-1}$ ), enquanto a maior média foi obtida no sistema silvipastoril (1,562  $\mu\text{mol m}^{-2} \text{s}^{-1}$ ).

O sistema silvipastoril no Cerrado apresentou os maiores valores de emissão total de CO<sub>2</sub> (2,01 Mg ha<sup>-1</sup>) ao longo dos 35 dias de estudo na estação seca do ano.

Os dados foram observados em períodos curtos na estação seca quando a atividade microbiana é mínima no solo, mas mesmo assim, diferenças significativas foram observadas, e esses resultados são importantes para melhor caracterizar a emissão de CO<sub>2</sub> ao longo do tempo e auxiliar na tomada de decisão no manejo a ser utilizado quando o objetivo é mitigar a emissão de gases de efeito estufa para a atmosfera.

A análise de componentes principais apresenta-se como uma alternativa eficaz na discriminação de sistemas de produção e sua relação com as propriedades do solo. Os resultados aqui apresentados, demonstram que a FCO<sub>2</sub> é altamente correlacionada com a temperatura nos sistemas de pastagem manejada e degradada.

Este estudo mostrou que as RNAs forneceram modelos preditivos para explicar a variação espaço-temporal da emissão de CO<sub>2</sub>, no entanto, novas metodologias de mineração de dados precisam ser empregadas, a fim de aperfeiçoar a seleção do conjunto de dados para o treinamento. Novos estudos precisam ser realizados, uma vez que o aprendizado de máquina é pouco utilizado na previsão da respiração do solo. A complexidade das redes não influenciou na previsão do CO<sub>2</sub>. O melhor desempenho foi observado no modelo individual na área de pastagem degradada com uma rede MLP. Quando foi utilizada a análise de componentes principais como variável de entrada para o treinamento das redes no modelo global, todas as redes tiveram um melhor desempenho. A umidade do solo e a temperatura contribuem para a explicação da variação temporal da respiração do solo.

## REFERÊNCIAS

ADUAN, R.; ENGEL, M. F. V.; KLINK, C. A. "Ciclagem de carbono em ecossistemas terrestres: o caso do cerrado brasileiro." **Embrapa Cerrados-Documents (INFOTECA-E)**, 2003.

ALARI, F. O. **Fluxo de gases de efeito estufa na implantação de sistema silvipastoril em pastejo com ovinos**. 2016. 130 f. Tese (Doutorado em Zootecnia) - Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista "Júlio De Mesquita Filho", Jaboticabal; 2016.

ALMEIDA, J. A.; CORREA, J.; SCHMITT, C. Clay Mineralogy of Basaltic Hillsides Soils in the Western State of Santa Catarina. **Revista Brasileira de Ciências do Solo**, v. 42, p. 1-17, 2018.

BASARIR, H.; KUMRAL, M.; KARPUZ, C.; TUTLUOGLU, L. Geostatistical modeling of spatial variability of SPT data for a borax stockpile site. **Engineering Geology**, v. 114, n. 3-4, p. 154-163, 2010.

BERNADINO, F. S. **Sistema silvipastoril com eucalipto: produtividade do sub-bosque e desempenho de novilhos sob fertilização nitrogenada e potássica**. 2007. 112 f. Tese (Doutorado em Zootecnia) - Universidade Federal de Viçosa, Viçosa, 2007.

BERNOUX, M.; CERRI, C. C.; CERRI, C. E. P.; SIQUEIRA NETO, M.; METAY, A.; PERRIN, A.; SCOPEL, E.; BLAVET, D.; PICCOLO, M.C. Influence du semis direct avec couverture végétale sur la séquestration du carbone et l'érosion au Brésil. **Bulletin Du Réseau Érosion**, v. 23, p. 323-337, 2004.

BRASIL. Ministério da Ciência, Tecnologia e Inovação. **Estimativas anuais de emissões de gases de efeito estufa no Brasil**. 4 ed. Brasília, 2017. 190p.

BRITO, L. F.; MARQUES JÚNIOR, J.; PEREIRA, G. T.; SOUZA, Z. M.; LA SCALA, N. Soil CO<sub>2</sub> emission of sugarcane field as affected by topography. **Scientia Agricola**, v. 66, n. 1, p. 77-83, 2009.

BRITO, L. F.; MARQUES JUNIOR., J.; PEREIRA, G. T.; LA SCALA JR, N. Spatial variability of soil CO<sub>2</sub> emission in different topographic positions. **Bragantia**, v. 69, p. 19-27, 2010.

CARDOSO, A. S. **Avaliação das emissões de gases do efeito estufa em diferentes cenários de intensificação de uso das pastagens no Brasil Central**. 2012. 97 f. **Dissertação (Mestrado em Agronomia) – Instituto de Agronomia, Universidade Federal Rural do Rio de Janeiro, Rio de Janeiro, 2012.**

CARPENTER, G. A.; GROSSBERG, S. A. Massively parallel architecture for a self-organizing neural pattern recognition machine. **Computer Vision, Graphics and Image Processing**, v. 37, n. 1, p. 54-115, 1987.

CARVALHO, J. L. N.; RAUCCI, G. S.; CERRI, C. E. P.; BERNOUX, M.; FEIGL, B. J.; WRUCK, F. J.; CERRI, C. C. Impact of pasture, agriculture and crop-livestock

systems on soil C stocks in Brazil. **Soil & Tillage Research**, v. 110, n. 1, p. 175-186, 2010.

CHEN, X.; DHUNGEL, J.; BHATTARAI, S. P.; TORABI, M.; PENDERGAST, L.; MIDMORE, D. J. Impact of oxygenation on soil respiration, yield and water use efficiency of three crop species. **Journal of Plant Ecology**, v. 4, p. 236-248, 2010.

COSTA, F. S.; BAYER, C.; ZANATTA, J. A.; MIELNICZUK, J. Estoque de carbono orgânico no solo e emissões de dióxido de carbono influenciadas por sistemas de manejo no sul do Brasil. **Revista Brasileira de Ciência do Solo**, v. 32, n. 1 p. 323-332, 2008.

DASSELAAR, A. V. P. V.; CORRÉ, W. J.; PRIEMÉ, A.; KLEMEDTSSON, Å. K.; WESLIEN, P.; STEIN, A.; KLEMEDTSSON, L.; OENEMA, O. Spatial variability of methane, nitrous oxide and carbon dioxide emissions from drained grassland. **Soil Science Society America Journal**, v. 62, n. 33, p. 810-817, 1998.

DEMATTE, J. A. M.; EPIPHANIO, J. C. N.; FORMAGGIO, A. R. Influência da matéria orgânica e de formas de ferro na reflectância de solos tropicais. **Bragantia**, v. 62, n. 3, p. 451-464, 2003.

DAVIDSON, E. A.; JANSSENS, I. A. Temperature sensitivity of soil carbon decomposition and feedbacks to climate change. **Nature**, v. 440, n. 7081, p. 165–173, 2006.

DI C.; Yang X.; Wang X. A Four-Stage Hybrid Model for Hydrological Time Series Forecasting. **Plos One**, v. 9, p. 1-18, 2014.

DOLAN, M. S.; CLAPP, C. E.; ALLMARAS, R. R.; BAKER, J. M.; MOLINA, J. A. E. Soil organic carbon and nitrogen in a Minnesota soils as related to tillage, residue and nitrogen management. **Soil & Tillage Research**, v. 89, n. 2, p. 221-231, 2006.

DUAH-YENTUMI, S.; RØNN, R.; CHRISTENSEN, S. Nutrients limiting microbial growth in a tropical forest soil of Ghana under different management. **Applied Soil Ecology**, v. 8, n. 1-3, p.19-24, 1998.

EMBRAPA - Desafios e perspectivas na recuperação de pastagens degradadas na Amazônia, Belém, 2015.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUARIA- EMBRAPA. **Agropecuária brasileira em números**. [Home page]. Disponível em: <<http://www.agricultura.gov.br/assuntos/politica-agricola/agropecuaria-brasileira-em-numeros>>. Acesso em: 19 dez. 2019.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUARIA- EMBRAPA. **Manual de métodos de análise de solo**. 2. ed. Brasília: Ministério da Agricultura e do Abastecimento / EMBRAPA-CNPS, 1997. 212 p.

FIGUEIREDO, E. B.; PANOSSO, A. R.; BORDONAL, R. O.; TEIXEIRA, D. D. B.; BERCHIELLI, T. T.; LA SCALA, N. Soil CO<sub>2</sub>-C emissions and correlations with soil

properties in degraded and managed pastures in southern Brazil. **Land Degradation & Development**, v.28, p. 1163-1492, 2016.

FRANK, A. B.; LIEBIG, M. A.; TANAKA, D. L. Management effects on soil CO<sub>2</sub> efflux in northern semiarid grassland and cropland. **Soil & Tillage Research**, v. 89, n. 1, p. 78-85, 2006.

FREITAS, L.P.S. **Previsão da Variabilidade da Emissão de CO<sub>2</sub> do Solo em Áreas de Cana-de-Açúcar Utilizando Redes Neurais Artificiais**. 2016. 89 f. Tese (Doutorado em Engenharia Elétrica) - Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista "Júlio de Mesquita Filho", Ilha Solteira. 2016.

GARTEN, C. T.; CLASSEN, A. T.; NORBY, R. J. Soil moisture surpasses elevated CO<sub>2</sub> and temperature as a control on soil carbon dynamics in a multi-factor climate change experiment. **Plant & Soil**, v. 319, n. 1-2, p. 85–94, 2009.

GHRITLAHRE H. K.; PRASAD R. K. Investigation of thermal performance of unidirectional flow porous bed solar air heater using MLP, GRNN, and RBF models of ANN technique. **Thermal Science and Engineering Progress**, v. 6, p. 226–235, 2018.

GRAF, A.; HERBST, M.; WEIHERMÜLLER, L.; HUISMAN, J. A.; PROLINGHEUER, N.; BORNEMANN, L.; VERECKEN, H. Analyzing spatiotemporal variability of heterotrophic soil respiration at the field scale using orthogonal functions. **Geoderma**, v. 181–182, n. 2, p. 91–101, 2012.

GRAUPE, D. **Principles of artificial neural networks**. 3<sup>rd</sup>, World Scientific. 2013.

HAIR, J. F.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E; TATHAM, R. L. **Análise multivariada de dados**. Bookman editora. São Paulo, 2009.

HAYKIN, S. **Neural networks: a comprehensive foundation**. 2<sup>a</sup> ed. Canada, Prentice, 2001.

HU, W.; SHAO, M.; HAN, F.; REICHARDT, K. Spatio-temporal variability behavior of land surface soil water content in shrub- and grass-land. **Geoderma**, v. 162, n. 3–4, p. 260–272, 2011.

HUNTER, A.; KENNEDY, L.; HENRY, J.; FERGUSON, I. Application of neural networks and sensitivity analysis to improved prediction of trauma survival. **Computer Methods and Programs in Biomedicine**, n.62, p.11-19, 2000.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC. **Climate change and Land: Special Report on Climate Change, Desertification, Land Degradation, Sustainable Land Management, Food Security, and Greenhouse gas fluxes in Terrestrial Ecosystems 2013: mitigation**. Geneva: [s.n.], 2019. Disponível

em: <[https://www.ipcc.ch/site/assets/uploads/sites/4/2019/12/02\\_Summary-forPolicymakers\\_SPM.pdf](https://www.ipcc.ch/site/assets/uploads/sites/4/2019/12/02_Summary-forPolicymakers_SPM.pdf)>. Acesso: 18 dez .2019.

ISAAKS, E. H.; SRIVASTAVA, R. M. **Applied geostatistics**. Nova York: Oxford University Press. 1989. 561 p.

JOLLIFFE I. T. Discarding Variables in a Principal Component Analysis. I: Artificial Data. **Journal of the Royal Statistical Society. Series C (Applied Statistics)**, v. 2, n. 21, pp. 160- 173, 1972.

KANG, S.; DOH, S.; LEE, D.; LEE, D.; JIN, V. L.; KIMBALL, J. Topographic and climatic controls on soil respiration in six temperate mixed-hardwood forest slopes, Korea. **Global Change Biology**, v. 9, n. 3, p. 1.427-1.437, 2003.

KASHANINEJAD, M.; DEHGHANI, A. A.; KASHIRI, M. Modeling of wheat sing two artificial neural networks (MLP anda RBF). **Journal of Food Engineering**, v. 91, p. 602-607, 2009.

KOVACS, Z. L. **Redes Neurais Artificiais: Fundamentos e Aplicações: Um texto básico**. 4ª ed. Editora Livraria da Física, 2006.

LA SCALA, N.; MARQUES, J.; PEREIRA, G. T.; CORA, J. E. Carbon dioxide emission related to chemical properties of a tropical bare soil. **Soil Biology & Biochemistry**, v. 32, n. 10, p. 1469-1473, 2000.

LAL, R. Challenges and opportunities in soil organic matter research. **European Journal of Soil Science**, v. 60, n. 2, p. 158–169, 2009.

LAL, R. Soil carbon sequestration and aggregation by cover cropping. **Journal Soil Water Conservation**, v. 70, n. 6, 329–339, 2015.

LIMA, C. M.; LABIDI, S. **Introdução à inteligência artificial**. São Luiz: FAPEMA, 1999.

LUO, Y.; ZHOU, X. **Soil respiration and the environment**. Burlington: Academic Press, 2006.

MALTONI, K. L. **Estudo de Compactação e/ou Adensamento em Subsuperfície de Latosso sob diferentes usos**. 1994. 73 p. Tese (Doutorado em Solos e nutrição de plantas) - Universidade Federal de Viçosa, Viçosa,1994.

MEIRELES, H. T.; MARQUES JUNIOR, J.; CAMPOS, M. C. C.; PEREIRA, G. T. Relações solo-paisagem em topossequência de origem basáltica. **Pesquisa Agropecuária Tropical**, v.42, n. 2, p.129-136, 2012.

MEIXNER, F. X.; YANG, W. X. Biogenic emissions of nitric oxide and nitrous oxide from arid and semi-arid land. In: D'ODORICO, P.; PORPORATO, A. (Ed.). **Dryland ecohydrology**. Dordrecht: Springer, 2006. p. 233–255.

MELLO, MARÍLIA TERRA. **Aplicação de redes neurais artificiais no processo de precificação de ações**. 2004. 50 p. Monografia - Instituto de Física e Matemática, Universidade Federal de Pelotas, Pelotas, 2004.

McCULLOCH, W.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v.5, p.115-133, 1943.

MOITINHO, M. R.; PADOVAN, M. P.; DA SILVA BICALHO, E.; FERRAUDO, A. S.; TEIXEIRA, D. D. B.; DE SOUZA BAHIA, A. S. R.; PINHEIRO, D. P.; VASQUEZ, L. N.; LA SCALA JR, N. Short-Term Soil CO<sub>2</sub> Emission and Soil Attributes Under Contrasting Sugarcane Cultivars. **Sugar Tech**, v. 20, n. 6, p. 658-668, 2018.

MOITINHO, M. R.; PADOVAN, M. P.; PANOSSO, A. R.; TEIXEIRA, D. D. B.; FERRAUDO, A. S.; LA SCALA JR, N. On the spatial and temporal dependence of CO<sub>2</sub> emission on soil properties in sugarcane (*Saccharum* spp.) production. **Soil and Tillage Research**, v. 148, p.127-132, 2015.

MORELL, F. J.; ÁLVARO-FUENTES, J.; LAMPURLANÉS, J.; CANTERO-MARTÍNEZ, C. Soil CO<sub>2</sub> fluxes following tillage and rainfall events in a semiarid Mediterranean agroecosystem: Effects of tillage systems and nitrogen fertilization. **Agriculture, Ecosystems & Environment**, v. 139, n. 1–2, p. 167–173, 2010.

NETO, J. M. M.; MOITA, G. C. Uma introdução à análise exploratória de dados multivariados. **Química Nova**, v. 21, n. 4, p. 467- 469, 1998.

NOOJIPADY, P.; MORTON, C. D.; MACEDO, N. M.; VICTORIA, C. D.; HUANG, C.; GIBBS, K. H.; BOLFE, L. E. Forest carbon emissions from cropland expansion in the Brazilian Cerrado biome. **Environmental Research Letters**, v. 12, n. 2, p. 1-12, 2017.

NOTTINGHAM, A. T.; MEIR, P.; VELASQUEZ, E.; TURNER, B. L. Soil carbon loss by experimental warming in a tropical forest. **Nature**. v. 584, n. 7820, p. 234-237, 2020.

OGLE, S. M.; PAUSTIAN, K. Soil organic carbon as an indicator of environmental quality at the national scale: monitoring methods and policy relevance. **Canadian Journal of Soil Science**, v. 85, p. 531-540, 2005.

OLIVEIRA, C. F. **Variabilidade espacial da emissão de CO<sub>2</sub> e estoque de carbono do solo em áreas de eucalipto e sistema silvipastoril**. 2018. 65 f. Dissertação (Mestrado em Agronomia) – Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Ilha Solteira, 2018.

PANOSSO, A. R.; MARQUES JR, J.; PEREIRA, G. T.; LA SCALA JR, N. Spatial and temporal variability of soil CO<sub>2</sub> emission in a sugarcane area under green and slash-and-burn managements. **Soil & Tillage Research**, v. 105, n. 2, p. 275- 282, 2009.

PANOSSO, A. R.; MARQUES, J.; MILORI, D. M. B. P.; FERRAUDO, A. S.; BARBIERI, D. M.; PEREIRA, G. T.; LA SCALA, N. Soil CO<sub>2</sub> emission and its relation to soil properties in sugarcane areas under Slash-and-burn and Green harvest. **Soil Tillage & Research**, v. 111, n. 2, p. 190–196, 2011a.

- PANOSSO, A. R. **Variabilidade espacial da emissão de CO<sub>2</sub> e sua relação com propriedades do solo em área de cana-de-açúcar no sudeste do Brasil**. 2011. 122 f. Tese (Doutorado em Agronomia) – Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Jaboticabal, 2011b.
- PANOSSO, A. R.; PEREIRA, G. T.; MARQUES JÚNIOR, J.; LA SCALA J. N. Variabilidade espacial da emissão de CO<sub>2</sub> em Latossolos sob cultivo de cana-de-açúcar em diferentes sistemas de manejo. **Engenharia Agrícola**, v. 28, n. 2, p. 227-236, 2008.
- PRIES, C. E. H.; CASTANHA, C.; PORRAS, R. C.; TORN, M. S. The whole-soil carbon flux in response to warming. **Science**, v. 355, n. 6332, p. 1420–1423, 2017.
- RAIJ, B. V.; ANDRADE, J. C.; CANTARELLA, H.; QUAGGIO, J. A. **Análise química para avaliação da fertilidade de solos tropicais**. Campinas: Instituto Agronômico, 285 p. 2001.
- RAMOS, J. C. A. **Emissão de CO<sub>2</sub>, quantidade e qualidade do carbono do solo em sistemas agrícolas na região do cerrado do Mato Grosso do Sul**. 2018. 86 f. Dissertação (Mestrado em Agronomia) – Faculdade de Engenharia de Ilha Solteira, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Ilha Solteira, 2018.
- RAYMENT, M. B.; JARVIS, P. G. Temporal and spatial variation of soil CO<sub>2</sub> efflux in a Canadian boreal forest. **Soil Biology & Biochemistry**, v. 32, n. 1, p. 35-45, 2000.
- RESCK, D.V.S. Agricultural intensification systems and their impact on soil and water quality in the Cerrados of Brazil. In: LAL, R. ed. **Soil quality and agricultural sustainability**. Chelsea: Ann Arbor Press, 1998. p. 288-300.
- RETH, S.; REICHSTEIN, M.; FALGE, E. The effect of soil water content, soil temperature, soil pH-value and the root mass on soil CO<sub>2</sub> efflux - A modified model. **Plant and Soil**, v. 268, n. 1-2, p. 21-33, 2005.
- ROCHA, S. J. S. S.; SCHETTINI, B. L. S.; ALVES, E. B. B. M.; VILLANOVA, P. H.; TORRES, C. M. M. E.; JACOVINE, L. A. G.; NETO, S. N. O.; BRIANEZI, D. Balanço de carbono em três sistemas silvipastoril no Sudeste do Brasil. **Revista Espacius**, v. 38, n. 39, p. 33-40, 2017.
- ROCHETTE, P.; DESJARDINS, R. L.; PATTEY, E. Spatial and temporal variability of soil respiration in agricultural fields. **Canadian Journal of Soil Science**, v. 71, n. 2, p. 189-196, 1991.
- RODEGHIERO, M.; CHURKINA, G.; MARTINEZ, C.; SCHOLTEN, T.; GIANELLE, D.; CESCATTI, A. Components of forest soil CO<sub>2</sub> efflux estimated from  $\Delta 14\text{C}$  values of soil organic matter. **Plant and soil**, v. 364, n. 1-2, p.55-68, 2013.
- ROLIM, G. S.; CAMARGO, M. B. P.; LANIA, D. G.; MORAES, J. F. L. Classificação climática de Köppen e de Thornthwaite e sua aplicabilidade na determinação de

zonas agroclimáticas para o Estado de São Paulo. **Bragantia**, v. 66, n. 4, p. 711-720, 2007.

ROSCOE, R.; MERCANTE, F. M.; SALTON, J. C. Dinâmica da matéria orgânica do solo em sistemas conservacionistas: modelagem matemática e métodos auxiliares. **Embrapa Agropecuária Oeste-Livro técnico (INFOTECA-E)**, 2006.

RUBIO, V. E.; DETTO, M. Spatiotemporal variability of soil respiration in a seasonal tropical forest. **Ecology and Evolution**, v. 7, n. 17, p. 7104–7116, 2017.

SAIZ, G.; GREEN, C.; BUTTERBACH-BAHL, K.; KIESE, R.; AVITABILE, V.; FARRELL, E. P. Seasonal and spatial variability of soil respiration in four *Sitka spruce* stands. **Plant and Soil**, v. 287, n. 1-2, p. 161-176, 2006.

SANTOS, D.; SOUZA, E. G. DE; NÓBREGA, L. H. P.; BAZZI, C. L.; GONÇALVES JÚNIOR, A. C. Variabilidade espacial de atributos físicos de um Latossolo Vermelho após cultivo de soja. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 16, n. 8, p. 843-848, 2012.

SANTOS, G. A. A.; MOITINHO, M. R.; OLIVEIRA SILVA, B.; XAVIER, C. V.; TEIXEIRA, D. D. B.; CORÁ, J. E. E.; JÚNIOR, N. L. S. Effects of long-term no-tillage systems with different succession cropping strategies on the variation of soil CO<sub>2</sub> emission. **Science of the total environment**, v. 686, p. 413-424, 2019.

SANTOS, H. G.; JACOMINE, P. K. T.; ANJOS, L. H. C.; OLIVEIRA, V. A.; OLIVEIRA, J. B.; COELHO, M. R.; LUMBRERAS, J. F.; CUNHA, T. J. F. **Sistema brasileiro de classificação de solos**. Rio de Janeiro: Embrapa Solos, 2018. p. 353.

SARTORI, F.; LAL, R.; EBINGER, M. H.; PARRISH, D. J. Potential soil carbon sequestration and CO<sub>2</sub> offset by dedicated energy crops in the U.S.A. **Critical Reviews in Plant Sciences**, v. 25, n. 5, p. 441-472, 2006.

SILVA, A. P. D. Efficient Variable Screening for Multivariate Analysis. **Journal of Multivariate Analysis**, v. 76, p. 35-62, 2001.

SIX, J.; FREY, S. D.; THIES, R. K.; BATTEN, K. M. Bacterial and fungal contributions to carbon sequestration in agroecosystems. **Soil Science Society America Journal**, v. 70, n. 2, p. 555–569, 2006.

SMITH, K. A.; BALL, T.; CONEN, F.; DOBBIE, K. E.; MASSHEDER, J.; REY, A. Exchange of greenhouse gases between soil and atmosphere: interactions of soil physical factors and biological processes. **European Journal of Oral Sciences**, v. 69, n.1, p. 10-20, 2018.

TAKI, M.; ROHANI, A.; SOHEILI-FARD, F.; ABDESHAHI, A. Assessment of energy consumption and modeling of output energy for wheat production by neural network (MLP and RBF) and Gaussian process regression (GPR) models. **Journal of Cleaner Production**, v. 172, p. 3028-3041, 2018.

TAVANTI, R. F. R.; MONTANARI, R.; PANOSSO, A. R.; LA SCALA JR, N.; NETO, M. C.; DA SILVA FREDDI, O.; GALINDO, F. S. What is the impact of pasture reform

on organic carbon compartments and CO<sub>2</sub> emissions in the Brazilian Cerrado?. **CATENA**, v. 194, p. 1-11, 2020.

TAVARES, R.; MORAES, L.; SIQUEIRA, D. S.; PANOSSO, A. R.; CASTIONI, G. A. F. SOUZA, Z. M.; SCALA J. NEWTON L. Soil management of sugarcane fields affecting CO<sub>2</sub> fluxes. **Scientia Agricola**, v. 73, n. 6, p. 543-551, 2016.

TRANGMAR, B. B.; YOST, R. S.; UEHARA G. Spatial dependence and interpolation of soil properties in West Sumatra, Indonesia 1. anisotropic variation. **Soil Science Society of America Journal**, v. 50, n. 6, p.1391-1395, 1986.

TREVISAN, R.; GONÇALVES, F.; ONÃ, S.; WRUCK, F. J.; TAVANTI, R. R.; PERES, F. S. C. Variability of physical properties of soil and rice grown under cover crops in crop-livestock integrated system. **Bragantia**, v. 76, n. 1, p. 145-154, 2017.

USSIRI, A. N.; LAL, R. Long-term tillage effects on soil carbon storage and carbon dioxide emissions in continuous corn cropping system from an alfisol in Ohio. **Soil & Tillage Research**, v. 104, n. 1, p. 39-47. 2009.

VICENTINI, M. E.; PINOTTI, C. R.; HIRAI, W. Y.; MORAES, M. L. T.; MONTANARI, R.; TEIXEIRA FILHO, M. C. M.; MILORI, D. M. B. P.; LA SCALA JR, N.; PANOSSO, A. R. CO<sub>2</sub> emission and its relation to soil temperature, moisture, and O<sub>2</sub> absorption in the reforested areas of Cerrado biome, Central Brazil. **Plant and Soil**, v. 444, p. 1-19, 2019.

VITAL, M. H. F. **Aquecimento global: acordos internacionais, emissões de CO<sub>2</sub> e o surgimento dos mercados de carbono no mundo**. BNDES, Rio de Janeiro, v. 24, n. 48, p. 167-244, 2018.

WALLACE, J. M.; HOBBS, P.V. **Atmospheric science: an introductory survey**. 2 ed. Elsevier, 2006.

WANG, J.; LIU, Q. Q.; CHEN, R. R.; LIU, W. Z.; SAINJU, U. M. Soil carbon dioxide emissions in response to precipitation frequency in the Loess Plateau, China. **Applied Soil Ecology**, v. 96, n. 4, p. 288–295, 2015.

WERBOS, P. J. **Beyond regression: new tools for prediction and analysis in the behavioral sciences**. 1974. 453 f. Thesis (Master) - Harvard University, Harvard, 1974.

WIDROW, B.; LEHR, M. A. 30 years of adaptive neural networks: perceptron, madaline, and backpropagation. **Proceedings of the IEEE**, v. 78, n. 9, p. 1415-1442, 1990.

XAVIER, C. V.; MOITINHO, M. R.; TEIXEIRA, D. D. B.; ARAÚJO SANTOS, G. A.; DE ANDRADE BARBOSA, M.; MILORI, D. M. B. P.; JÚNIOR, N. L. S. Crop rotation and succession in a no-tillage system: Implications for CO<sub>2</sub> emission and soil attributes. **Journal of environmental management**, v. 245, p. 8-15, 2019.

XAVIER C.V.; MOITINHO M. R.; TEIXEIRA D. D.; ARAÚJO, S. G. A.; CORÁ, J. E.; LA SCALA JR. N. Crop rotation and sequence effects on temporal variation of CO<sub>2</sub> emissions after long-term no-till application. **Science of The Total Environment**, v. 20, n. 709, p. 136107, 2020.

XU, M.; QI, Y. Soil surface CO<sub>2</sub> efflux and its spatial and temporal variations in a young ponderosa pine plantation in northern California. **Global Change Biology, Champaign**, v.7, n.1, p.667-677, 2001.