

## **Luciana Paro Scarin Freitas**

**“Previsão da Variabilidade da Emissão de CO<sub>2</sub> do  
Solo em Áreas de Cana-de-Açúcar Utilizando  
Redes Neurais Artificiais”**



UNIVERSIDADE ESTADUAL PAULISTA  
"JÚLIO DE MESQUITA FILHO"  
Campus de Ilha Solteira

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

## **Luciana Paro Scarin Freitas**

# **“Previsão da Variabilidade da Emissão de CO<sub>2</sub> do Solo em Áreas de Cana-de-Açúcar Utilizando Redes Neurais Artificiais”**

Tese apresentada ao Programa de Pós Graduação em Engenharia Elétrica da Faculdade de Engenharia – UNESP – Campus de Ilha Solteira, para obtenção do título de Doutor em Engenharia Elétrica.  
Área de Conhecimento: Automação.

Orientadora: Prof. Dra. Anna Diva Plasencia Lotufo.

Ilha Solteira

2016

F866p Freitas, Luciana Paro Scarin.  
Previsão da variabilidade da emissão de CO<sub>2</sub> do solo em áreas de cana-de-açúcar utilizando redes neurais artificiais / Luciana Paro Scarin Freitas. -- Ilha Solteira: [s.n.], 2016  
89 f. : il.

Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Sistemas De Energia Elétrica, 2016

Orientador: Anna Diva Plasencia Lotufo  
Inclui bibliografia

1. Redes neurais artificiais. 2. Modelos de previsão. 3. Variabilidade espacial.  
4. Respiração do solo. 5. Cana-de-açúcar. 6. Emissão de gás carbônico.

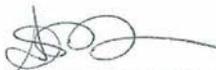
CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: Previsão da variabilidade da emissão de CO<sub>2</sub> do solo em áreas de cana-de-açúcar utilizando redes neurais artificiais

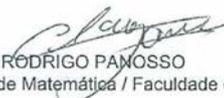
AUTORA: LUCIANA PARO SCARIN FREITAS

ORIENTADORA: ANNA DIVA PLASENCIA LOTUFO

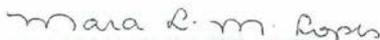
Aprovada como parte das exigências para obtenção do Título de Doutora em ENGENHARIA ELÉTRICA, área: AUTOMAÇÃO pela Comissão Examinadora:



Profa. Dra. ANNA DIVA PLASENCIA LOTUFO  
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira



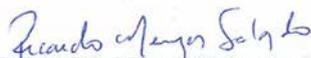
Prof. Dr. ALAN RODRIGO PANOSSO  
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira



Profa. Dra. MARA LUCIA MARTINS LOPES  
Departamento de Matemática / Faculdade de Engenharia de Ilha Solteira



Prof. Dr. JOSÉ GUILHERME MAGALINI SANTOS DECANINI  
Câmpus de Presidente Epitácio / Instituto Federal de São Paulo - IFSP



Prof. Dr. RICARDO MENEZES SALGADO  
Instituto de Ciências Exatas / Universidade Federal de Alfenas

Ilha Solteira, 05 de setembro de 2016

Ao meu esposo Ricardo Luiz Barros de Freitas.

À minha filha Lorena Scarin Freitas.

Aos meus pais:

José Antonio Scarin

e

Luiza Izabel Paro Scarin.

Dedico

Aos meus irmãos:

Lucila Paro Scarin Correia

e

Leandro Paro Scarin.

À minha família.

Aos meus amigos.

Ofereço

Que nunca nos falte.... Fé, Coragem,  
Disposição e Sabedoria .... Para que possamos ir  
em busca de nossos sonhos e objetivos.

## **AGRADECIMENTOS**

Agradeço, primeiramente, a Deus, por ter me dado o dom da vida e por me amparar e acompanhar em todos os momentos.

Agradeço a todas as pessoas que me incentivaram e me apoiaram durante o doutorado, ao meu esposo Ricardo Luiz Barros de Freitas, que sempre me incentivou em minha formação pessoal, acadêmica e profissional e por ter me dado uma linda filha, a Lorena Scarin Freitas que é nossa razão de viver.

A minha filha Lorena Scarin Freitas que é o grande amor da minha vida, pela qual dedico todos os meus dias e meus esforços e a qual devo agradecer infinitamente por ter tido tanta paciência, mesmo sem saber. Agradeço por ter entendido todos os momentos que não pude lhe dar mais atenção.

Aos meus pais Luiza Izabel Paro Scarin e José Antonio Scarin que dedicaram suas vidas em prol da minha formação e que sempre estiveram ao meu lado, me ajudando de todas as maneiras dentro de suas possibilidades.

Aos meus irmãos Lucila e Leandro, meus amigos e amados que também sempre me encorajaram para seguir em frente. Aos meus cunhados Patrícia e Eduardo grandes companheiros e aos meus sobrinhos Arthur e Ana Júlia.

A minha orientadora, a professora Anna Diva Plasencia Lotufo por ter me proporcionado a oportunidade de realizar este trabalho, aprimorar os meus conhecimentos e por orientar minhas ações direcionando os meus estudos, além de ser uma grande amiga.

A minha grande amiga e também norteadora do meu trabalho, a professora Mara Lúcia Martins Lopes, que, esteve sempre presente me orientando em minhas necessidades até mesmo nos momentos mais delicados de sua vida. A toda a sua família que com muita paciência, amor e carinho acolheram a mim e a minha família. E especialmente ao seu filho Matheus que em muitos momentos me cedeu à atenção de sua mãe.

Ao professor Alan Rodrigo Panosso e Newton La Scala Júnior, que me proporcionaram a oportunidade de realizar meu trabalho utilizando as informações de suas pesquisas e principalmente pela orientação e ensinamentos durante a realização do meu doutorado.

Ao professor Carlos Roberto Minussi pela atenção, orientação e amparo nos momentos de necessidades.

Aos professores do Departamento de Engenharia Elétrica, Ricardo Tokio Higuti, Rubén Augusto Romero Lázaro, José Roberto Sanches Mantovani e todos os demais que de alguma forma colaboraram para meu trabalho.

Ao meu grande amigo Uiliam Nelson Lenzion T. Alves por me auxiliar inúmeras vezes em todos os momentos que precisei e a minha grande amiga Nair Rodrigues que sempre me deu suporte em todas as minhas necessidades.

Aos meus familiares e amigos que de muitas formas, em muitas ocasiões, deram valiosas contribuições durante a realização deste trabalho.

Ao CNPQ, a FAPESP e a CAPES.

## RESUMO

O dióxido de carbono ( $\text{CO}_2$ ) é considerado um dos principais gases do efeito estufa adicional e contribui significativamente para as mudanças climáticas globais. Áreas agrícolas oferecem uma oportunidade para mitigar esse efeito, uma vez que, dependendo de seu uso e manejo, são capazes de armazenar grandes quantidades de carbono, retirando-as da atmosfera. A produção de  $\text{CO}_2$  no solo é resultado de processos biológicos, como a decomposição da matéria orgânica e respiração de raízes e organismos do solo, fenômeno chamado de emissão de  $\text{CO}_2$  do solo ( $\text{FCO}_2$ ). O objetivo deste trabalho foi utilizar as redes neurais artificiais para estudo e previsão de padrões espaço-temporais da emissão de  $\text{CO}_2$  do solo em áreas de cana-de-açúcar em sistema de cana crua, colheita mecanizada, quando grandes quantidades de palhas são depositadas sobre a superfície do solo. Valores de  $\text{FCO}_2$  foram coletados em áreas de cultivo comercial no Sudeste do Estado de São Paulo, registrados por meio do sistema LI-8100, em gradeados amostrais para determinação da variabilidade espaçotemporal de  $\text{FCO}_2$ , e atributos físicos e químicos do solo. Foram utilizados dados referentes a estudos realizados nos anos de 2008, 2010 e 2012, no período após a operação de colheita mecânica da cultura. Uma rede neural Perceptron Multi-Camadas via algoritmo *backpropagation* foi aplicada para estimar a emissão de  $\text{FCO}_2$  do ano de 2012, utilizando os dados referentes aos anos de 2008 e 2010 para treinamento da rede neural. A rede neural inicialmente apresentou um MAPE de 18,3852 coeficiente de determinação  $R^2$  de 0,9188. Os dados obtidos do  $\text{FCO}_2$  observado e do  $\text{FCO}_2$  estimado apresentam moderada dependência espacial, e pelos mapas do padrão espacial do fluxo de  $\text{CO}_2$  é observado que a rede neural apresentou considerável similaridade com os dados observados, identificando os pontos característicos de maior emissão como também os de menor emissão de  $\text{CO}_2$ . Portanto, os resultados indicam que a rede neural artificial pode fornecer estimativas com confiabilidade para a avaliação de  $\text{FCO}_2$  a partir de dados de atributos físicos e químicos do solo, sendo capaz de caracterizar a variabilidade espaçotemporal desse atributo em áreas de cana-de-açúcar, sob o sistema de cana crua no Sudeste do Estado de São Paulo.

**Palavras-chave:** Modelos de previsão. Redes neurais artificiais. Variabilidade espacial.

## ABSTRACT

Carbon dioxide (CO<sub>2</sub>) is considered one of the main gases additional greenhouse effect and contributes significantly to global climate change. Agriculture areas offer an opportunity to mitigate this effect, since, depending on its use and handling, are capable of storing large amounts of carbon, removing them from the atmosphere. The CO<sub>2</sub> production in soil is the result of biological processes such as the decomposition of organic matter and breathing roots and soil organisms, a phenomenon called soil CO<sub>2</sub> emissions (FCO<sub>2</sub>). The aim of this study was to use artificial neural networks to study and forecast patterns spatiotemporal of soil CO<sub>2</sub> emission in areas of sugarcane in raw cane system, mechanical harvesting, when large amounts of straw are deposited on soil surface. FCO<sub>2</sub> values were collected in areas of commercial cultivation in southeastern of the state of São Paulo, registered through the LI-8100 system, sample grilles for determining the spatiotemporal variability of FCO<sub>2</sub>, and physical and chemical soil properties. The used data were from studies conducted in the years 2008, 2010 and 2012, in the period after the mechanical harvesting operation culture. A Multilayer Perceptron neural network with backpropagation algorithm was applied to estimate the emission of FCO<sub>2</sub> in the year 2012, using data from the years 2008 and 2010 to the neural network training. The neural network initially presented a MAPE of 18.3852 and determination coefficient R<sup>2</sup> of 0.9188. Data obtained from the observed FCO<sub>2</sub> and FCO<sub>2</sub> estimated present moderate spatial dependence, and observing the maps of the spatial pattern of the CO<sub>2</sub> flow show that neural network presents considerable similarity to the observed data, identifying the higher and lower characteristic points of CO<sub>2</sub> emissions. Therefore, the results indicate that the artificial neural network can provide reliability for the evaluation of FCO<sub>2</sub> from data of physical and chemical soil properties, being able to describe the spatiotemporal variability of this attribute in sugarcane fields, under the crude cane system in the southeastern of the state of São Paulo.

**Keywords:** Forecasting models. Artificial neural networks. Spatial variability.

## LISTA DE ILUSTRAÇÕES

Figura 1 - Fenômeno do efeito estufa. ....	29
Figura 2 - Balanço energético anual médio da Terra. ....	30
Figura 3 - Média global combinada da temperatura da superfície terrestre e oceânica. ....	34
Figura 4 - Média global do nível do oceano. ....	35
Figura 5 - Média global das concentrações de gases com efeito de estufa. ....	36
Figura 6 - Contribuição percentual dos biomas para as emissões líquidas de CO <sub>2</sub> em 2012 para o setor de Mudança do Uso da Terra e Florestas. ....	37
Figura 7 - Constituintes da célula neuronal. ....	44
Figura 8 - Modelo do neurônio de McCulloch-Pitts. ....	45
Figura 9 - Funções de ativação. ....	46
Figura 10 - Rede neural artificial. ....	47
Figura 11 - Fluxo de processamento do algoritmo com as fases <i>forward</i> e <i>backward</i> . ....	53
Figura 12 - Arquitetura da rede neural utilizada processo inicial. ....	57
Figura 13 - Arquitetura da rede neural utilizada. ....	62
Figura 14 - Gráfico da previsão da rede MLP ( <i>backpropagation</i> ). ....	65
Figura 15 - Gráfico da previsão da rede MLP ( <i>Levenberg-Marquardt</i> ). ....	66
Figura 16 - Gráfico da previsão da rede MLP ( <i>backpropagation e Levenberg-Marquardt</i> ). ...	67
Figura 17 - Gráfico da previsão da rede MLP (Pesos atualizados). ....	68
Figura 18 - Gráfico da previsão da rede MLP (100 dados no treinamento). ....	69
Figura 19 - Gráfico da previsão da rede MLP (50 dados no treinamento). ....	70
Figura 20 - Gráfico da previsão da rede MLP com filtro passa-baixas. ....	71
Figura 21 - Gráfico da rede Neural GRNN. ....	72
Figura 22 - Gráfico da rede neural PNN. ....	73
Figura 23 - Resultado dos 1063 dados apresentado pela rede neural. ....	76
Figura 24 - Resultado dos 100 dados apresentado pela rede neural. ....	77
Figura 25 - Mapas do padrão espacial do fluxo de CO <sub>2</sub> do solo (FCO <sub>2</sub> ) observado (a) e estimado (b). ....	80

## LISTA DE TABELAS

Tabela 1 - Índices de Concentração de Gases de Efeito Estufa.....	33
Tabela 2 - Produção plantada de cana-de-açúcar no período de realização da coleta de dados. .....	41
Tabela 3 - Produção colhida de cana-de-açúcar no período de realização da coleta de dados (em hectares). .....	41
Tabela 4 - Informações geográficas, histórico e período de condução dos estudos nas áreas do estado de São Paulo. ....	55
Tabela 5 - Parâmetros da rede neural MLP e respectivos valores, utilizados para a fase de treinamento e diagnóstico.....	63
Tabela 6 - Saídas reais medidas (SRM) e saídas obtidas pela da rede neural MLP (SO) que representam a identificação de emissão de CO <sub>2</sub> .....	64
Tabela 7 - Redes testadas e resultados parciais. ....	74
Tabela 8 - Amostras (Am), saídas reais medidas (SRM) e saídas obtidas pela rede neural MLP (SO) que representam a identificação de emissão de CO <sub>2</sub> do solo.....	75
Tabela 9 - Modelos e estimativas dos parâmetros ajustados aos variogramas experimentais da emissão de CO <sub>2</sub> do solo (observados e estimados pela rede), nos diferentes dias de avaliação do ano de 2012.....	79

## SIMBOLOGIA

Símbolo	Descrição	Símbolo	Descrição
$a$	Alcance.	H+Al	Acidez Potencial.
Ar	Argônio.	H <sub>2</sub> O	Água.
C	Carbono.	HFC	Hidrofluorcarboneto.
CH <sub>4</sub>	Metano.	HCFC	Hidroclorofluorcarboneto.
CFC	Clorofluorcarbonetos.	h	Distância de separação entre pares de pontos.
CO <sub>2</sub>	Dióxido de Carbono.	K	Potássio.
C <sub>0</sub>	Efeito pepita.	$k$	Número de iterações.
C <sub>0</sub> +C <sub>1</sub>	Patamar.	m	Metro.
$d$	Máxima distância.	Mg	Magnésio.
CFCs	Clorofluorcarbonos	N <sub>2</sub>	Nitrogênio.
f(.)	Função não-linear.	N(h)	Números de pares de pontos separados pela distância h.
FCO <sub>2</sub>	Emissão do dióxido de carbono.	N <sub>2</sub> O	Óxido Nitroso.
$N$	Número de valores medidos dos $Z(x_i)$ envolvidos na estimativa.	$z^*$	Valor a ser estimado no ponto não amostrado $x_0$ .

NO <sub>2</sub>	Óxido Nítrico.	Z(x <sub>i</sub> )	Valor de FCO <sub>2</sub> no ponto x <sub>i</sub> .
O <sub>2</sub>	Oxigênio.	Z(x <sub>i</sub> +h)	Valor de FCO <sub>2</sub> no ponto x <sub>i</sub> +h.
O <sub>3</sub>	Ozônio.	λ <sub>i</sub>	Pesos associados a cada valor medido Z(x <sub>i</sub> ).
P	Fósforo.	η	Taxa de treinamento.
PgC	Petagrama de Carbono.	δ	Erro calculado.
R <sup>2</sup>	Coefficiente de Determinação.	γf	Derivada da função transferência.
Tg ano <sup>-1</sup>	Teragrama por ano.	γ	Saída do neurônio.
ω	Pesos.	(+)	Somador.
W/m <sup>2</sup>	Watt por metro quadrado.	σ	Fator de suavidade da curva gaussiana.

## SIGLAS

ACP	Componentes Principais.
Am	Amostras Utilizadas.
AR4	Quarto Relatório de Avaliação do IPCC.
ART	<i>Adaptive Resonance Theory.</i>
ART Fuzzy	<i>Adaptive Resonance Theory Fuzzy.</i>
BP	<i>Backpropagation.</i>
CEP	Coefficiente Efeito Pepita.
CC	Cana Crua.
COP 18	Conferência das Partes.
CQ	Cana Queimada.
CTC	Capacidade de Troca de Cátions.
Ds	Densidade do Solo.
Estc	Estoque de Carbono.
GEE	Gases do Efeito Estufa.
GRNN	Rede Neural Regressão Generalizada.
IPCC	Painel Intergovernamental sobre Mudanças Climáticas.
MAPE	Erro Percentual Absoluto Médio.
MLP	<i>Multilayer Perceptron.</i>
MO	Matéria Orgânica.
pH	Potencial Hidrogeniônico.
PLAm	Porosidade Livre de Água Média.
PNN	Rede Neural Probabilística.
ppbv	Partes por Bilhão por Volume.
ppmv	Partes por Milhão por Volume.
pptv	Partes por Trilhão por Volume.

RNA	Redes Neurais Artificiais.
SEM	Saída Real Medida.
SO	Saída Obtida.
SOM	<i>Self Organizing Map.</i>
Tm	Temperatura Média.
Um	Umidade Média.
UNICA	União das Indústrias de Cana-de-açúcar.
VTP	Volume Total de Poros do Solo.

## SUMÁRIO

1	INTRODUÇÃO GERAL .....	18
1.1	Introdução.....	18
1.2	Objetivo.....	21
1.3	Justificativa.....	21
1.4	Organização dos Capítulos.....	22
2	ESTADO DA ARTE.....	24
2.1	Definição do Problema.....	24
2.2	Análise de algumas Referências Bibliográficas sobre a emissão de CO <sub>2</sub> .....	24
3	EFEITO ESTUFA .....	28
3.1	Efeito Estufa .....	28
4	SOLOS .....	39
4.1	Solos e Cana-de-açúcar .....	39
5	REDES NEURAIS .....	43
5.1	Neurônio Biológico.....	43
5.2	Neurônio Artificial.....	44
5.3	Estrutura das Redes Neurais Artificiais .....	46
5.4	Treinamento ou Aprendizado .....	48
	5.4.1 <i>Treinamento Supervisionado</i> .....	48
	5.4.2 <i>Treinamento Não Supervisionado</i> .....	48
	5.4.3 <i>Redes neurais testadas nesse trabalho</i> .....	49
	5.4.4 <i>Redes MLP (Multilayer Perceptron)</i> .....	51
6	METODOLOGIA.....	55
6.1	Introdução.....	55
7	RESULTADOS E DISCUSSÃO.....	64
7.1	Resultados Iniciais Obtidos .....	64
7.2	Discussão.....	80
8	CONCLUSÃO.....	82
8.1	Publicações.....	83
	REFERÊNCIAS .....	84

# 1 INTRODUÇÃO GERAL

## 1.1 Introdução

A influência humana sobre o sistema climático é evidente, e as recentes emissões antrópicas de gases de efeito estufa são a maior da história IPCC (2014). Ainda, segundo o IPCC, políticas que regem as práticas agrícolas e de conservação e gestão das florestas são mais eficazes quando envolvem a mitigação e adaptação.

Segundo o Ministério da Ciência, Tecnologia e Inovação no relatório de Estimativas Anuais de Emissões de Gases de Efeito Estufa no Brasil em 2014 a contribuição percentual dos biomas para as emissões líquidas de dióxido de carbono (CO<sub>2</sub>) em 2012 para o setor de Mudança do Uso da Terra e Florestas no cerrado brasileiro corresponde a 72,50% e que entre os demais gases estufas, a contribuição do CO<sub>2</sub> nesse cenário corresponde a 90%.

De acordo com o Painel Internacional sobre Mudanças Climáticas (IPCC), o avanço de emissões antropogênicas de gases do efeito estufa (GEE) é a causa dominante do aquecimento global.

“Reflexões sobre o propagado aquecimento global deixam evidente que o clima do Planeta, sem exagero, é resultante de tudo o que ocorre no Universo.”  
“... o bom senso sugere a adoção de políticas de conservação ambiental bem elaboradas, destituídas de dogmatismo, e mudanças nos hábitos de consumo para que a Humanidade possa sobreviver, isto é, para que as gerações futuras possam dispor dos recursos naturais que se dispõem atualmente. Portanto, a conservação ambiental é necessária e independente do aquecimento ou resfriamento global.” Molion (2008)

O Brasil, apesar de não ter metas obrigatórias de redução de dióxido de carbono (CO<sub>2</sub>), assumiu o compromisso voluntário de reduzir suas emissões até o ano de 2020, sendo signatário de diversos acordos multilaterais para o esforço global de mitigação dos GEE. Ao contrário de outros países, cuja queima de combustíveis fósseis é a principal fonte de GEE, as emissões brasileiras são originadas, principalmente, em mudanças no uso da terra e florestas, com as queimadas e o desmatamento liderando este processo, (BRASIL, 2004).

Mundialmente, a agricultura é responsável pela emissão antrópica de quantidades significativas dos chamados gases estufas CO<sub>2</sub>, metano (CH<sub>4</sub>) e óxido nitroso (N<sub>2</sub>O) para atmosfera, contribuindo com 11%, 47% e 58% das emissões totais desses gases, respectivamente (IPCC, 2007). No Brasil, a participação da agricultura na emissão de CO<sub>2</sub> no total das emissões antrópicas é de 75%, devido ao uso e mudança da terra associado a tal atividade (CERRI et al., 2007).

Dependendo do uso e manejo, os solos agrícolas podem atuar como fontes ou sumidouros de carbono da atmosfera (USSIRI ;LAL, 2009). De acordo com Rayment e Jarvis (2000), o balanço de carbono em um ecossistema é representado pela quantidade de carbono absorvida pela fotossíntese e a quantidade de carbono perdida no processo de respiração do solo. Pequenos incrementos nas taxas de respiração podem ser suficientes para um ecossistema mudar de sumidouro a fonte de carbono para a atmosfera. As emissões oriundas do solo, associadas à perda de carbono do solo via emissão de CO<sub>2</sub> em áreas agrícolas, frequentemente não são consideradas devido à sua grande variação espaço temporal e por ser um fenômeno resultante de uma interação complexa dos atributos físicos, químicos, biológicos e climáticos (EPRON et al., 2006; TEIXEIRA et al., 2012; MOITINHO et al., 2013).

O Brasil é o maior produtor de cana-de-açúcar do mundo. No país, a área cultivada com cana-de-açúcar é de aproximadamente de 10,8 milhões de hectares de área plantada, sendo o Estado de São Paulo o maior produtor nacional. São estimados mais de 5,7 milhões hectares cultivados de cana-de-açúcar com uma produção de 367,2 milhões de toneladas de cana-de-açúcar (UNICA, 2015). As emissões dos GEE, no Brasil, têm sido medidas em áreas de cana-de-açúcar, devido à grande importância da cultura na produção de biocombustível (FIGUEIREDO ; LA SCALA, 2011). Assim, estimativas da emissão de CO<sub>2</sub> do solo em áreas de cana-de-açúcar são importantes para a diminuição das incertezas associadas ao processo de cálculo de balanço de carbono para o país.

A estratégia principal para o aumento do sequestro de carbono, em áreas agrícolas, é a minimização da decomposição e da mineralização do carbono orgânico do solo, por ações de manejo do solo que promovam a proteção desse carbono e aumente a deposição de resíduos das culturas sobre a superfície do solo, como o sistema de cana crua (PANOSSO et al., 2011).

Para a realização deste trabalho, que envolve diretamente as emissões antrópicas do gás carbônico na atmosfera, sobretudo a quantidade emitida em áreas agrícolas, é proposto a utilização de redes neurais artificiais para a realização da previsão da emissão do respectivo gás, em função das redes neurais serem excelentes ferramentas aplicadas em casos de previsão, pois as mesmas são capazes de aprenderem, processar informações e apresentarem respostas.

Todo ser humano possui um Sistema Nervoso que, entre outras funções, é responsável pelo ajuste do organismo ao ambiente, que é composto pelo sistema nervoso central, responsável por processar informações, e pelo sistema nervoso periférico responsável pela condução dessas informações pelo corpo. As células nervosas, denominadas neurônios, são responsáveis pelo recebimento e transporte de informações, por meio de alterações elétricas, os

chamados impulsos elétricos. No cérebro humano, os neurônios captam os sinais através de inúmeras estruturas finas chamadas dendritos (terminais de entrada) e enviam atividades elétricas através de um longo e fino suporte conhecido como axônio (terminal de saída) (MENDES ; CARVALHO, 1997).

O neurônio artificial é baseado no neurônio biológico, sendo assim, uma rede neural artificial é um grupo de neurônios artificiais interconectados interagindo de uma forma combinada, ou seja, um estímulo é aplicado na entrada da rede, e após algumas operações satisfatórias, encontra-se uma saída desejada.

Haykin (1999) define Redes Neurais Artificiais (RNA) 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, 1999). “Elas se assemelham ao cérebro humano em dois aspectos: a) o conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizado e forças de conexão entre neurônios, conhecidas como pesos sinápticos; b) são utilizadas para armazenar o conhecimento adquirido” (HAYKIN, 1999).

Segundo Schultz, Wieland e Lutze (2000) as redes neurais artificiais (RNAs) são uma excelente alternativa para modelar sistemas não lineares e que são complexos demais para serem descritos por métodos analíticos e são capazes de determinar um padrão de reconhecimento, diagnóstico e previsão.

Segundo Lima e Labidi (1999), as Redes Neurais Artificiais podem ser definidas como conjuntos bem estruturados de unidades de processamento, interligadas por canais de comunicação, cada qual tendo um determinado peso correspondente a um valor numérico. Elas consistem de unidades de processamento (neurônios) conectadas entre si formando uma disposição estrutural de camadas e conexões entre as camadas.

A capacidade de aprendizagem que as RNAs possuem de aprender através de exemplo e de generalizar as informações aprendidas, as tornam um excelente instrumento que propõem soluções interessantes em diversas áreas do conhecimento, inclusive na agronomia como apresenta o trabalho. As redes neurais são capazes de extrair as informações relevantes dos padrões de entrada que lhes são apresentados e através deste conhecimento conseguem gerar uma representação própria do problema.

Uma das características mais importantes das redes neurais é a habilidade de aprender e com isso melhorar seu desempenho. A rede é treinada de maneira que um conjunto de dados

de entrada produza o conjunto de saída desejada (estimada) ou pelo menos consistente, segundo Mendes e Carvalho (1997) e Wasserman (1989).

As redes neurais podem ser de única camada ou múltiplas camadas. A rede que foi utilizada neste trabalho é uma rede neural de múltiplas camadas chamada *MultiLayer Perceptron* (MLP). A rede MLP tem sido utilizada com sucesso para a solução de vários problemas envolvendo altos graus de não linearidade.

Seu treinamento é do tipo supervisionado e utiliza um algoritmo chamado retropropagação (*backpropagation*). Este algoritmo é baseado numa regra de aprendizagem que corrige o erro durante o treinamento (HAYKIN, 1999). Os erros observados nas unidades da camada escondida são determinados pelo erro propagado na direção inversa das unidades da camada de saída. Por esta razão, o método é chamado algoritmo de aprendizagem BP (*backpropagation*), de acordo com Krose e Smagt (1996). O algoritmo BP possui como vantagem o fato de trabalhar com redes multicamadas e resolver problemas não-linearmente separáveis que alguns algoritmos não resolvem, ou seja, é capaz de separar duas classes distintas no eixo cartesiano bidimensional sem a obrigatoriedade de traçar uma única reta.

Este trabalho foi desenvolvido utilizando, dados utilizados originários de áreas de cana-de-açúcar no sistema de manejo de cana crua (colheita mecanizada) onde os resíduos vegetais (folhas e colmos) foram deixados sob a superfície do solo.

## 1.2 Objetivo

O objetivo deste trabalho foi investigar a utilização de Redes Neurais Artificiais para realizar a previsão da variabilidade da emissão de CO<sub>2</sub> do solo, em áreas de cana de açúcar no sistema de cana crua no Sudeste do Estado de São Paulo, em função dos atributos físicos e químicos do solo.

## 1.3 Justificativa

A atmosfera terrestre é composta por gases que, entre outras funções, mantêm a temperatura do planeta estável, regulando as chuvas e possibilitando a vida em sua superfície. O aquecimento global é o pior problema ambiental da atualidade. O dióxido de carbono CO<sub>2</sub> é responsável por mais de 80% da poluição que gera o aquecimento global e é o mais significativo dos gases do Efeito de Estufa (GEE), conforme Sobreiro, Araújo e Nagano (2009).

A preocupação com a redução dos gases do efeito estufa é mundial, esta já foi discutida internacionalmente em vários eventos, como o Protocolo de Kyoto que foi assinado em 1997 e que prevê a redução da emissão de gases poluentes, onde, acordos foram realizados para que países se comprometessem a tomar medidas que visam reduzir as emissões de gases poluentes.

Na agricultura a maioria dos dados ecológicos e das variáveis envolvidas no processo de emissão de CO<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) segundo Bender (1996).

Considerando tais aspectos, a proposta deste trabalho é utilizar a aplicação de Redes Neurais Artificiais para realizar a previsão de CO<sub>2</sub> do solo em áreas de cana-de-açúcar contribuindo efetivamente para a análise e possíveis interferências no processo de redução do respectivo gás na atmosfera. Foram utilizadas as Redes GRNN, PNN e MLP, contudo a rede MLP foi a que melhor se adaptou a situação proposta e apresentou excelente resultado.

Com a adequação das Redes Neurais Artificiais para avaliar os dados coletados, será possível contribuir com a análise criteriosa dos profissionais da área, pois a previsão realizada pela rede poderá auxiliá-los em ações que visem reduzir a emissão de CO<sub>2</sub> na atmosfera.

#### 1.4 Organização dos Capítulos

O trabalho foi organizado em sete capítulos, da seguinte forma:

No Capítulo 2 é feito um estudo do estado da arte, no qual é definido o problema proposto e realizada a análise de algumas referências bibliográficas relacionadas com o trabalho.

O Capítulo 3 aborda os conceitos relacionados ao Efeito Estufa, suas causas, consequências e medidas mundialmente decididas com o intuito de amenizar o problema.

O Capítulo 4 aborda o tipo de solo, tipo de manejo e plantio de cana-de-açúcar no estado de São Paulo.

O Capítulo 5 descreve os principais conceitos relacionados às Redes Neurais Artificiais: neurônios biológicos, neurônios artificiais, Redes Neurais MLP (*Multilayer Perceptron*).

No Capítulo 6 é apresentada a metodologia, o desenvolvimento e a utilização da Rede Neural MLP.

No Capítulo 7 são apresentados os resultados obtidos através da aplicação da arquitetura de redes neurais artificiais (MLP) na identificação da emissão de CO<sub>2</sub> do solo em áreas de cana-de-açúcar do solo.

O Capítulo 8 apresenta as conclusões e contribuições deste trabalho, retratando também, as sugestões para possíveis trabalhos futuros.

## 2 ESTADO DA ARTE

### 2.1 Definição do Problema

Inicialmente convém relatar e salientar que na literatura, existem poucas referências que tratam da análise e quantificação da emissão do fluxo de carbono em plantações agrícolas aplicando redes neurais artificiais. Até o presente momento não foi encontrado pela autora na literatura nenhum trabalho que teria sido feito especificamente voltado para a previsão do FCO<sub>2</sub> (fluxo de gás carbônico) do solo em plantações de cana-de-açúcar utilizando redes neurais.

O setor da agricultura brasileira tem trabalhado no sentido de aprimorar suas metodologias visando mais eficiência vinculada à redução de custos e principalmente o impacto ambiental. Nesse contexto a aplicação das redes neurais artificiais é bastante atrativa, já que a forma como estes são apresentados internamente pela rede cria a possibilidade de um desempenho superior ao dos modelos convencionais (BRAGA et al., 2000).

### 2.2 Análise de algumas Referências Bibliográficas sobre a emissão de CO<sub>2</sub>

Esta análise relata algumas referências sobre a emissão de CO<sub>2</sub> apresentadas por pesquisadores que fazem uso desses conceitos e métodos associados a este tema.

Em seu trabalho, Soares et al. (2005) desenvolveram uma pesquisa que tinha por objetivo ajustar equações para estimar o carbono presente no fuste das espécies de árvores de *Eucalyptus grandis* e a quantidade de estoque de carbono, com idade entre 32 e 80 meses. Foram selecionadas e medidas a altura total e o DAP (Diâmetro com casca a 1,30m do solo) de 532 espécies para o ajuste das equações. Ainda, forneceram as estimativas de biomassa da madeira e casca do fuste, através da retirada de discos e casca da madeira encontrando a densidade básica. Verificaram que as equações se ajustaram bem aos dados observados após a análise dos coeficientes e da determinação das equações, para estimar o carbono total no fuste e o carbono da madeira, com o nível de probabilidade chegando a 95% em relação à escolha dos coeficientes significativos.

No trabalho de Lentzsch, Wieland e Wirth (2005), os autores utilizaram um modelo de regressão e uma rede neural artificial em um conjunto de 89 dados para a avaliação da biomassa microbiana do solo (BMS) de 30 locais na Alemanha, utilizando rede neural *feedforward* multicamadas construída e testada, e utilizou o algoritmo *Levenberg-Marquardt* para o treinamento. O modelo construído usou uma configuração com dois ou quatro neurônios

ocultos e um neurônio de saída. Os resultados apontaram que tanto o modelo de regressão linear abordagem completa-fatorial, bem como a rede neural foram promissoras ferramentas para a previsão de BMS.

Um estudo foi realizado por Saathi et al. (2007) para mapear a distribuição da biomassa na floresta amazônica. Os dados foram coletados por sensoriamento remoto e tinham o objetivo de medir o fluxo de carbono na região. No trabalho foram utilizadas cerca de 500 medições em diferentes áreas da Bacia Amazônica. Para realizar o trabalho os autores não utilizaram técnicas de redes neurais, optaram por escolher métodos estatísticos de correlação entre as medições feita no campo e os dados de sensoriamento remoto, e conseguiram estimar a quantidade total de carbono na floresta com uma margem de erro de aproximadamente 20%, incluindo não somente a biomassa acima do solo, mas também sob o solo.

Uma pesquisa financeira realizada por Sobreiro, Araújo e Nagano (2009) estimou os valores do combustível Etanol no Brasil, o qual também apresenta a particularidade de emissão de CO<sub>2</sub> na atmosfera. O trabalho utilizou redes neurais artificiais usando a arquitetura *Perceptron* multicamadas, com o do método ARIMA para previsão do preço do Etanol Combustível. Conclui-se que a aplicação das RNAs obteve uma aproximação mais satisfatória quando comparada à aplicação do método ARIMA quanto aos dados reais, o que evidencia a aplicabilidade das redes neurais na previsão dos preços do Etanol Combustível.

No trabalho de Garcia e Sperling (2011), os autores pesquisaram sobre a emissão de gases do efeito estufa na obtenção do etanol de cana-de-açúcar em diferentes cenários em Minas Gerais, a avaliação realizada considerou diversos cenários tecnológicos formados a partir de etapas produtivas envolvidas nos processos de agricultura e industrialização da cana-de-açúcar. Os dados foram coletados a partir de processos de licenciamento ambiental de 11 usinas do Estado de Minas Gerais, incluindo usinas de álcool e usinas de açúcar e álcool. Foram levantados dados de consumo e utilização de insumos que serviram de base para a estimativa das emissões de GEE em cada etapa produtiva. Foram determinados 180 cenários para produção de etanol com suas respectivas emissões. A partir da Análise de Variância foi realizada uma classificação dos cenários tecnológicos, de acordo com seu nível de emissões de GEE. Os resultados mostraram que as emissões de GEE na produção de etanol dependem do cenário tecnológico considerado e que há diferenças significativas nas emissões quando comparam-se grupos de cenários tecnológicos diferentes.

Um estudo foi desenvolvido por Mehdawi e Bin Ahmad (2012) com a finalidade de realizar estimativas quanto as incertezas nas emissões de gases de efeito estufa, especificamente

do gás carbônico. Este estudo foi realizado na Malásia e o autor utilizou técnicas de redes neurais artificiais e sensoriamento remoto. O estudo foi desenvolvido em escala global e regional que observou e monitorou as mudanças nas copas das árvores das florestas, que já tinham passado por processos de desmatamento, realizando uma comparação com imagens originais de uma região onde existiam várias espécies de árvores e, da mesma área, agora já urbanizada. O uso das técnicas de redes neurais artificiais possibilitou à pesquisa obter um resultado satisfatório com a precisão de acertos de quase 96,55%.

Um trabalho sobre a Predição do Sequestro do Carbono em Área Reflorestada e utilizou redes neurais artificiais foi realizado por Nunes et al, (2013). A pesquisa teve como objetivo propor o desenvolvimento de um sistema inteligente, utilizando redes neurais, para prever, seja a curto, médio ou de longo prazo, o sequestro (absorção) de carbono em áreas de reflorestamento, em uma fazenda situada na Amazônia Mato-Grossense com 10 mil hectares. O sistema proposto utilizou uma composição formada por uma rede neural da família ART (*Adaptive Resonance Theory*). Os resultados obtidos na comparação entre os valores reais e os estimados pela Rede Neural ART-*Fuzzy*-BP, na análise de cada talhão, apresentaram valores do MAPE (erro percentual absoluto médio) inferiores a 2% e os do Erro Máximo em quase 4%, ou seja, com significativo grau de confiabilidade no que diz respeito à metodologia adotada, atestando e validando o sistema inteligente proposto, no sentido de investigar a sua eficiência, provando que o sistema é viável, útil e bastante vantajoso, quando utilizado como técnicas de predição do sequestro de CO<sub>2</sub> em áreas reflorestadas, comparado com a literatura especializada.

Em seu trabalho, Song et al. (2014), analisaram estimativas do FCO<sub>2</sub> em florestas na China, em função de atributos do solo e variáveis meteorológicas, observaram que o modelo de redes neurais artificiais MLP com três camadas, treinada com algoritmo *backpropagation* e o método gradiente descendente, foi uma abordagem eficaz para prever a FCO<sub>2</sub> em todos ecossistemas florestais chineses. O trabalho mostrou que a FCO<sub>2</sub> médio de cada tipo de floresta na China foi próximo àqueles reportados nos ecossistemas florestais semelhantes, em outras regiões em todo o mundo. Os resultados também apontaram que o aumento da temperatura do ar pode aumentar fortemente a respiração das raízes e a atividade microbiana em tais regiões, levando a alta do FCO<sub>2</sub>, contribuindo, assim, para o aumento do efeito estufa adicional.

Nesse contexto, realizar a previsão do FCO<sub>2</sub> em áreas de cana-de-açúcar pode contribuir significativamente para adequações de manejo do solo para que se reduza a emissão de CO<sub>2</sub> na atmosfera, contribuindo, assim, para a redução do efeito estufa adicional. Além disso,

a utilização dessa metodologia pode ser uma ferramenta para a diminuição das incertezas associadas às estimativas desse importante componente do ciclo do carbono na atmosfera.

Dependendo da natureza da aplicação e da coerência dos padrões dos dados de entrada, em geral, ter-se-á um treinamento adequado, e conseqüentemente um elevado nível de acurácia da rede. Assim, essas redes neurais podem ser aplicadas a problemas de relações dinâmicas ou não lineares. Elas suprem uma alternativa analítica que as técnicas convencionais limitam-se, muitas vezes, por suposições estritas de normalidade, linearidade, independência de variável, etc., conforme Hecht-Nielsen (1996).

### 3 EFEITO ESTUFA

No presente capítulo estão apresentados os conceitos relacionados ao efeito estufa, o aquecimento global e as principais ações realizadas voltadas para redução da emissão dos gases do efeito estufa (GEE) e do aquecimento global que é um problema mundial. Esta leitura possibilitará um maior entendimento da importância deste trabalho e da aplicabilidade.

#### 3.1 Efeito Estufa

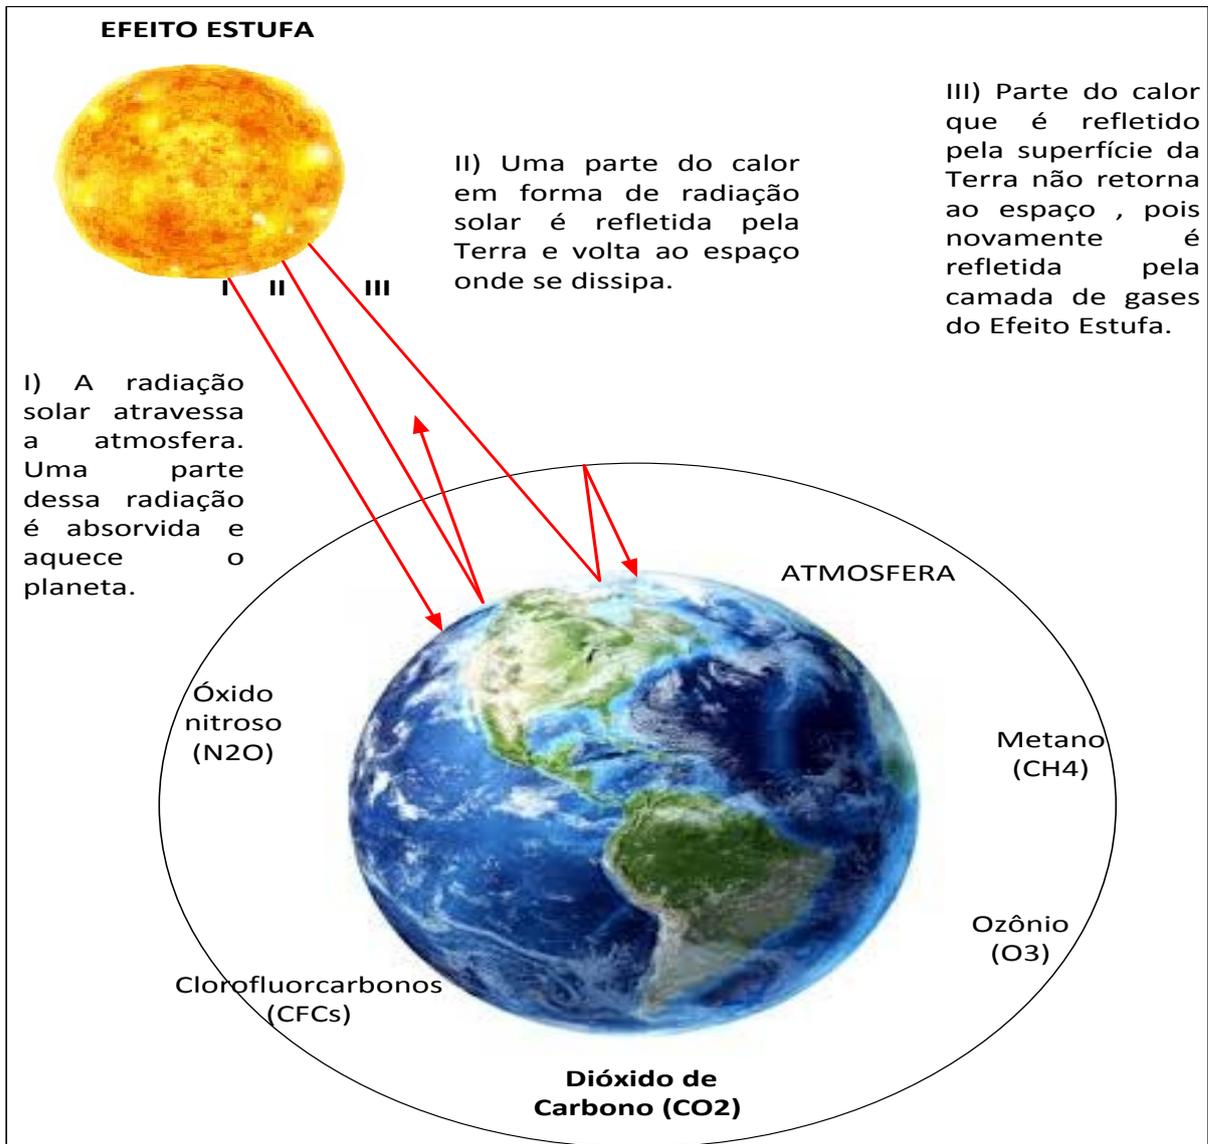
Considerado um fenômeno natural, o Efeito Estufa é controlado por determinados gases presentes na atmosfera e responsável pela manutenção das temperaturas da superfície terrestre. Esse fenômeno é resultante da interação entre os processos naturais de entrada de radiação eletromagnética do sol e a emissão de radiação térmica do planeta terra.

Este fenômeno pode ser benéfico, pois possibilita condições necessárias para existência de vida na terra, no entanto também apresenta aspectos maléficos, pois a intensificação do Efeito Estufa contribui para o aquecimento do planeta, também conhecido como Aquecimento Global e pode trazer consequências que afetam a vida na terra.

A radiação solar aquece o nosso planeta naturalmente. A Terra irradia aproximadamente a mesma quantidade de energia que provém do sol, pois há uma parcela de energia na Terra cuja origem não é solar, tais como a da fissão nuclear, a geotérmica e a associada à rotação da Terra. Como a Terra é um corpo muito mais frio do que o Sol, ela tende a irradiar no comprimento de onda do infravermelho.

A Figura 1 ilustra um esquema simplificado da composição do balanço de energia entre o Sol e a Terra e o fenômeno do efeito estufa.

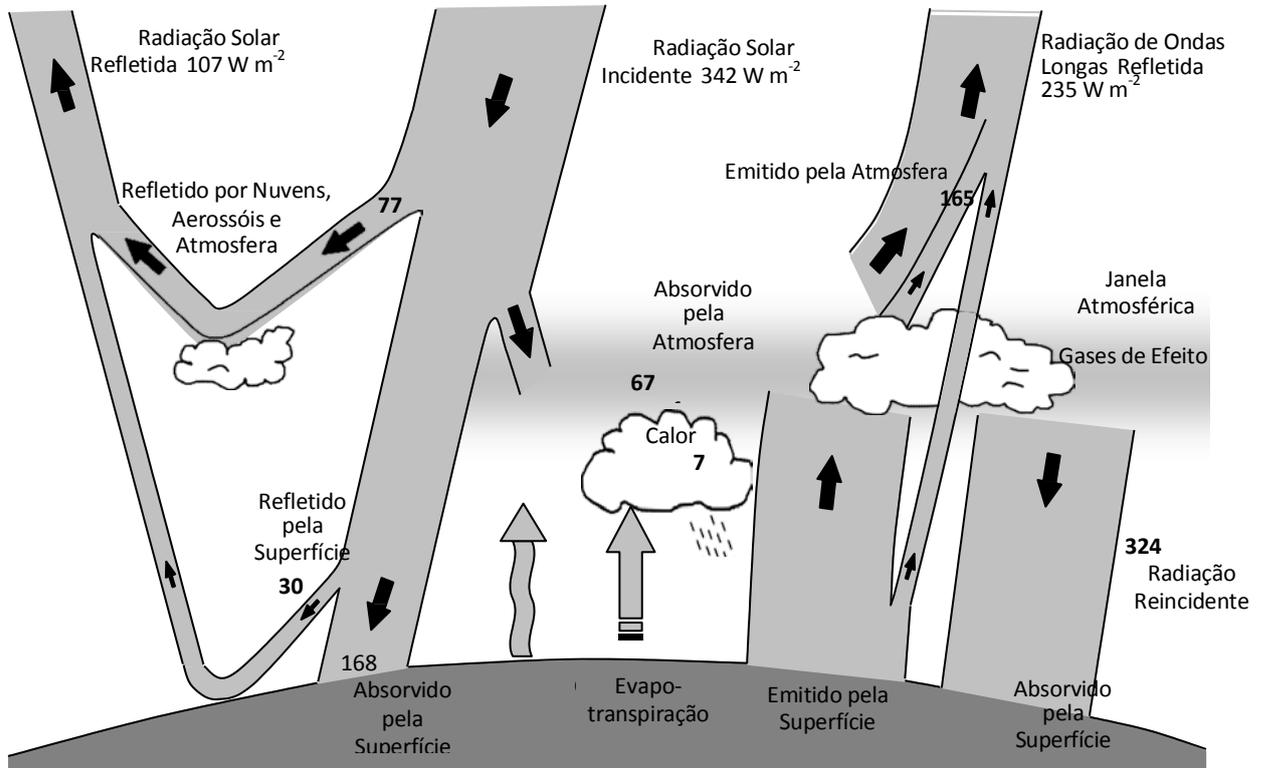
Figura 1 – Fenômeno do efeito estufa.



Fonte: Adaptado do IPCC 2014.

A fonte primária de energia para o planeta é o Sol, este emite energia na forma de radiação eletromagnética de ondas curtas, compreendendo regiões espectrais do ultravioleta, luz visível e do infravermelho. Uma parcela dessa radiação, aproximadamente 20%, é absorvida pela atmosfera (Figura 2), cerca de 49 % é absorvida pela superfície terrestre, e outros 31% são refletidos para o espaço pela atmosfera. Esta parcela refletida é denominada albedo planetário (KIEHL ; TRENBERTH, 1997).

**Figura 2 – Balanço energético anual médio da Terra.**



Fonte: (KIEHL ; TRENBERTH, 1997).

Segundo o *Intergovernmental Panel on Climate Change* (IPCC), a superfície da Terra irradia para a atmosfera uma média de  $390 \text{ W/m}^2$  de energia na forma de radiação infravermelha. Desses  $390 \text{ W/m}^2$ ,  $240 \text{ W/m}^2$  passam pela atmosfera e conseguem chegar ao espaço, enquanto que  $150 \text{ W/m}^2$  são absorvidos e reemitidos de volta pelos gases naturais de efeito estufa, ou seja, o efeito estufa natural pode ser definido como estes  $150 \text{ W/m}^2$  de radiação infravermelha que as moléculas dos gases de efeito estufa aprisionam e reemitem para a Terra. Este fenômeno mantém naturalmente a superfície da terra aquecida em torno de  $33^\circ \text{ C}$  em termos médios (IPCC,1995).

A discussão em torno do aquecimento global é intensa no cenário internacional. Cada vez mais países têm realizado acordos e se comprometido em realizar ações que visam a redução das emissões de Gases do Efeito Estufa (GEE) na atmosfera. Várias reuniões intergovernamentais foram realizadas para discutir e definir tais metas.

Em 1988, em Toronto no Canadá ocorreu a primeira reunião com líderes de países e classe científica para discutir sobre as mudanças climáticas, onde foi salientado que as mudanças climáticas têm impacto superado somente por uma guerra nuclear.

Em 1990, surgiu o IPCC (Painel Intergovernamental sobre Mudança Climática), considerado o primeiro mecanismo de caráter científico que visa alertar o mundo sobre o aquecimento do planeta. Constatou-se que alterações climáticas são principalmente provocadas por CO<sub>2</sub>.

Em 1992 aconteceu a Conferência das Nações Unidas sobre o Meio Ambiente e Desenvolvimento, realizada na cidade do Rio de Janeiro, Brasil. O evento ficou conhecido como ECO-92 ou Rio-92. Esse evento contou com a participação de mais de 160 líderes de Estado que assinaram a Convenção Marco Sobre Mudanças Climáticas, também foi realizado um balanço tanto dos problemas existentes quanto dos progressos realizados.

Na reunião, metas para que os países industrializados permanecessem no ano de 2000 com os mesmos índices de emissão do ano de 1990 foram estabelecidas. Nesse contexto, as discussões levaram à conclusão de que todos os países, independentemente de seu tamanho, devem ter sua responsabilidade de conservação e preservação das condições climáticas. Outro resultado de fundamental importância foi a assinatura da Agenda 21, um plano de ações com metas para a melhoria das condições ambientais do planeta. A Agenda 21 consiste em um acordo estabelecido entre 179 países para a elaboração de estratégias que objetivem o alcance do desenvolvimento sustentável.

Em 1997, na cidade japonesa Kyoto foi implementado o Protocolo de Kyoto, com a participação de oitenta e quatro países que se dispuseram a aderir ao protocolo e o assinaram. Dessa forma, comprometeram-se a implantar medidas com intuito de diminuir a emissão de gases do efeito estufa. O objetivo era firmar acordos e discussões internacionais para conjuntamente estabelecer metas de redução na emissão de gases-estufa na atmosfera, principalmente por parte dos países industrializados, além de criar formas de desenvolvimento de maneira menos impactante àqueles países em pleno desenvolvimento.

O objetivo principal do Protocolo de Quioto foi o de estabelecer metas concretas de redução de emissão de gases causadores do efeito estufa. O Protocolo estabeleceu no Anexo 1, que 40 países considerados desenvolvidos e em transição para economias de mercado, deveriam reduzir suas emissões totais de gases de efeito estufa, chegando a uma média de 5,2% abaixo das emissões de 1990, entre os anos de 2008 e 2012 que seria o primeiro período de compromisso. Cada país possuía metas diferenciadas, mas para que ocorresse essa redução, várias atividades econômicas teriam (e ainda tem) que ser modificadas através de algumas ações.

Segundo o Protocolo, os países não descritos no Anexo I, entre eles o Brasil, continuam, pelos termos deste instrumento, sem obrigação de reduzir suas emissões durante este primeiro período de compromisso (2008-2012), no entanto a isenção seria reavaliada para um próximo período de compromisso (pós-2012).

O protocolo entrou em vigor em 2005 e evidenciou o interesse de países em utilizar o carbono como moeda. Os EUA, o segundo país mais emissor de carbono do mundo, negou-se a ratificar o protocolo com a alegação de que aceitá-lo seria ruim para a economia americana. Em 2012 o protocolo teve sua validade prorrogada até 2020 após a Conferência das Partes (COP18). Desde então inúmeras reuniões vem sendo realizadas para firmar acordo e ações com o intuito de reduzir os GEE na atmosfera.

Segundo Brimblecombe (1996), a composição química em volume do ar seco e não poluído é de 78,084 % de Nitrogênio ( $N_2$ ), 20,946 % de Oxigênio ( $O_2$ ), 0,934 % de Argônio (Ar) e o restante é composto de gases em concentrações muito pequenas, denominados gases traços, no entanto com o aumento da umidade as proporções são sensivelmente alteradas. Na porção de gases que aparecem em menores proporções encontram-se os indutores do efeito estufa, como: o dióxido de carbono ( $CO_2$ ), metano ( $CH_4$ ), óxido nitroso ( $N_2O$ ), compostos clorofluorcarbonetos (CFC), hidroclorofluorcarbonetos (HCFC), hidrofluorcarbonetos (HFC), ozônio ( $O_3$ ) e Vapor d'água ( $H_2O$ ). Esses gases, que ocorrem na atmosfera como traços possuem alto potencial de interação com outros elementos químicos e com a radiação infravermelha.

Os principais gases antropogênicos causadores do fenômeno do aquecimento global são os seguintes:

- Dióxido de Carbono ( $CO_2$ ),
- Metano ( $CH_4$ ),
- Clorofluorcarbonos (CFCs),
- Óxido Nitroso ( $N_2O$ ).

Na Tabela 1 é possível visualizar os níveis de concentração dos principais gases causadores do efeito estufa, desencadeados pelo aumento da atividade industrial em meados de 1997 que ocasionou a preocupação mundial.

**Tabela 1 – Índices de Concentração de Gases de Efeito Estufa**

	CO <sub>2</sub>	CH <sub>4</sub>	CFC	N <sub>2</sub> O
Pré-Industrial 1750-1800	280 ppmv	0,8 ppmv	0	288 ppbv
Nível Atual	353 ppmv	1,72 ppmv	280 pptv	310 ppbv
Taxa Atual de Crescimento	0,50%	0,90%	4%	0,25%
Vida Média na Atmosfera (Anos)	50-200	10	65	150

ppmv= partes por milhão por volume, ppbv= partes por bilhão por volume; pptv= partes por trilhão por volume.  
Fonte: (UNEP, 1997)

Segundo a Estimation of Greenhouse Gas Emissions and Sinks (OECD) 1991, as principais fontes responsáveis, por tipo de gás emitido, são:

Dióxido de Carbono (CO<sub>2</sub>) - extração, transformação, transporte e uso final de combustíveis fósseis. Desmatamentos associados a queimadas de áreas florestadas.

Metano (CH<sub>4</sub>) - produzido através de processos de decomposição anaeróbica ou por combustão incompleta nas mudanças no uso do solo (cultivo de arroz em áreas alagadas, queima de biomassa - florestal e resíduos agrícolas, inundação de áreas florestadas em reservatórios) e áreas naturais pantanosas; criação de animais ruminantes (dejetos e criação), utilização energética (produção, armazenagem, queima de carvão mineral produção e transporte de gás natural).

Óxido Nitroso (N<sub>2</sub>O) - desnitrificação dos solos em condições anaeróbicas, combustão, queima da biomassa e utilização de fertilizantes.

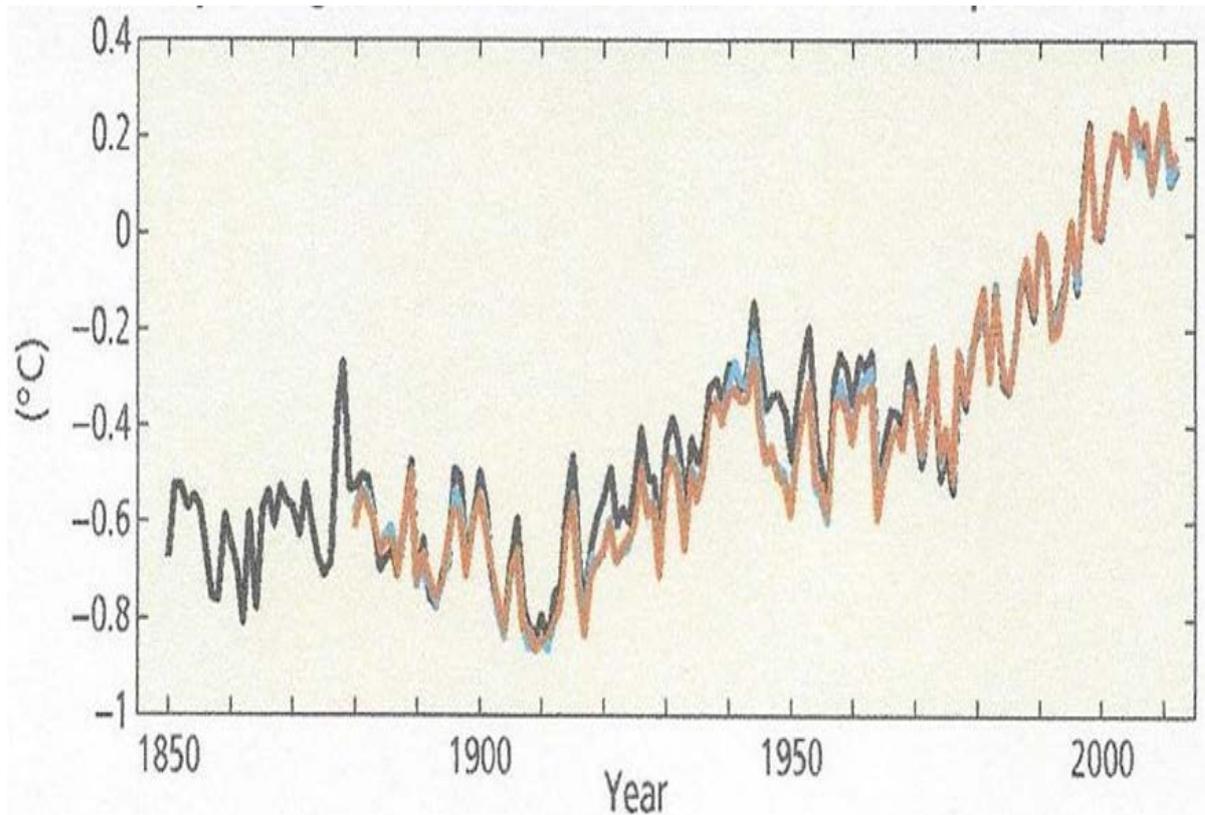
Clorofluorcarbonos (CFCs) - Atividade industrial, gases refrigerantes (ar condicionado, refrigeradores) e aerossóis.

Ozônio (O<sub>3</sub>) - Consequência de reações complexas na alta atmosfera (reação fotoquímica com o Monóxido de Carbono – (CO), metano – (CH<sub>4</sub>), e radicais oxidados de nitrogênio – (NO<sub>x</sub>)).

Pesquisas científicas sobre o efeito estufa, mostram que a temperatura global do planeta adquiriu uma tendência de subida ao longo do último século. Com base na literatura

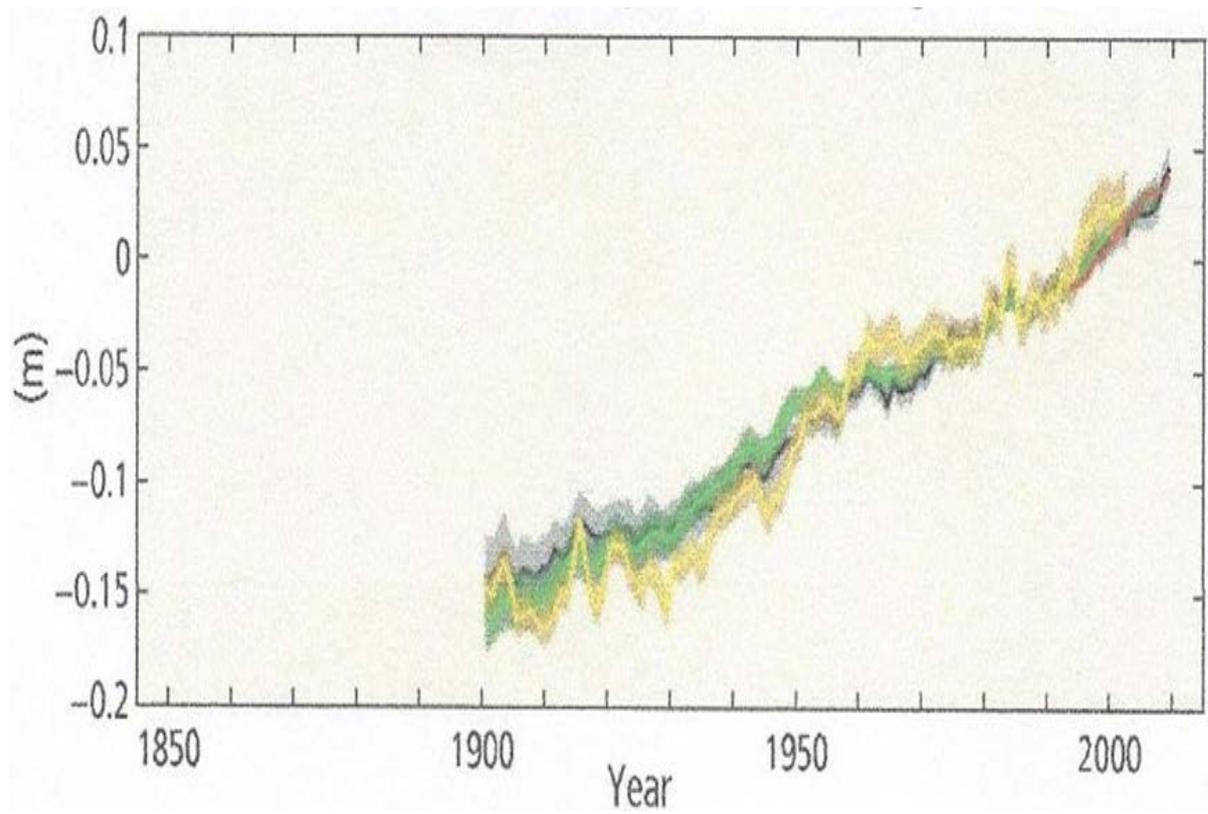
científica disponível desde o Quarto Relatório de Avaliação do IPCC (AR4), há substancialmente mais impactos nas últimas décadas agora atribuído à mudança climática. Segundo o IPCC (2014) a influência humana sobre o sistema climático é a maior da história, o que é notório observando as Figuras 3 a 5.

**Figura 3 – Média global combinada da temperatura da superfície terrestre e oceânica.**



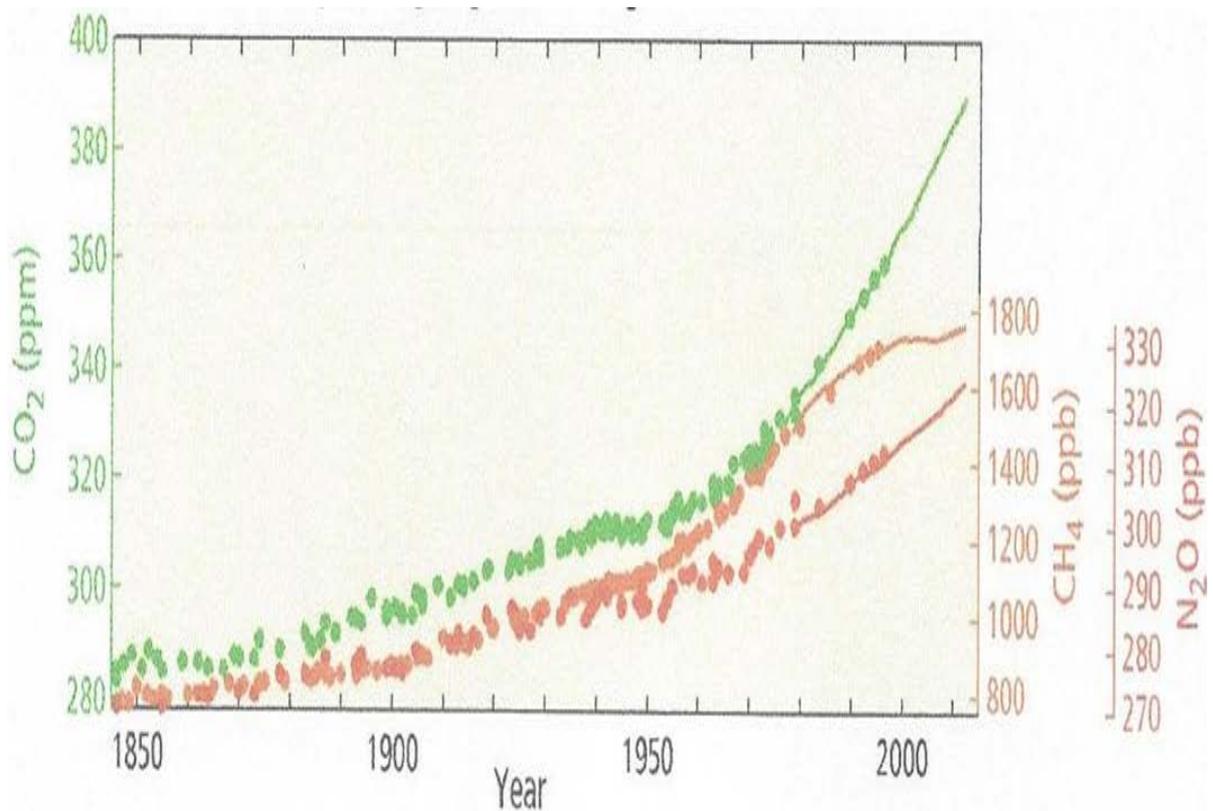
Fonte: IPCC (2014)

Figura 4 – Média global do nível do oceano.



Fonte: IPCC (2014).

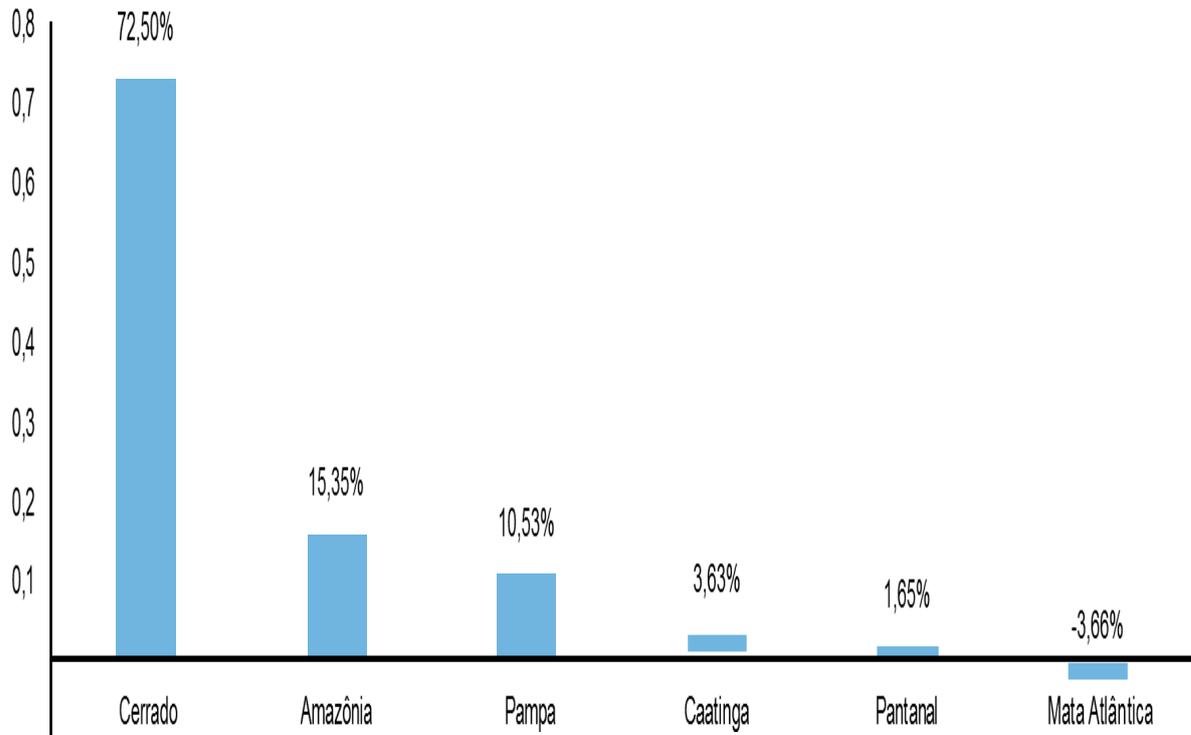
Figura 5 – Média global das concentrações de gases com efeito de estufa.



a curva superior representa o CO<sub>2</sub>, a curva intermediária representa o CH<sub>4</sub> e a curva inferior representa o N<sub>2</sub>O.  
 Fonte: IPCC (2014).

No Brasil, o Relatório do Ministério da Ciência, Tecnologia e Inovação (2014), sobre as Estimativas Anuais de Emissões de Gases de Efeito Estufa no Brasil, mostra as contribuições dos biomas para as emissões líquidas de CO<sub>2</sub> do setor de Mudança do Uso da Terra e Florestas em 2012, ilustradas na Figura 6.

**Figura 6 – Contribuição percentual dos biomas para as emissões líquidas de CO<sub>2</sub> em 2012 para o setor de Mudança do Uso da Terra e Florestas.**



Fonte: Relatório do Ministério da Ciência, Tecnologia e Inovação 2014.

Na ilustração da Figura 6 nota-se que a região do cerrado brasileiro, região analisada e apresentada nesse trabalho é a região que possui a maior e mais considerável contribuição de emissão de CO<sub>2</sub> no cenário brasileiro. Ainda de acordo com o mesmo relatório (p. 90), a estimativa da contribuição da emissão de CO<sub>2</sub> é de 90%, enquanto que a de CH<sub>4</sub> é de 9% e a de NO<sub>2</sub> de 1%. O que mostra o quanto o CO<sub>2</sub> é responsável nesse processo do efeito estufa. Segundo Kiehl e Tranberth (1997) o CO<sub>2</sub> é o segundo maior responsável pelo efeito estufa, respondendo por 26% do fenômeno. Segundo o IPCC 2014, (p. 868) práticas e tecnologias agrícolas inovadoras podem desempenhar um papel central na mitigação das alterações climáticas.

Observatórios, responsáveis por informar os índices do dióxido de Carbono (CO<sub>2</sub>), apontam que já alcançamos a marca de 400 ppm pela primeira vez desde o início das medições, em 1958. Segundo informações do IPCC (painel de mudanças climáticas da ONU), o ideal seria manter a concentração abaixo de 450 ppm para evitar que a temperatura chegasse ao limite, capaz de provocar sérios danos em todo o ecossistema. Desde 2000, a taxa de crescimento da

concentração de CO<sub>2</sub> vem aumentando mais rapidamente do que nas décadas anteriores, afirma Canadell et al. (2007).

## 4 SOLOS

Neste capítulo são abordados os tipos de solo brasileiro, tipo de manejo, plantio de cana-de-açúcar no Estado de São Paulo, que possibilitará um melhor entendimento a respeito da fonte dos dados utilizados no trabalho.

### 4.1 Solos e Cana-de-açúcar

O Brasil possui diferentes tipos de solo e a classificação é realizada através do Sistema Brasileiro de Classificação de Solos, publicado originalmente pela Embrapa em 2013 e que está em constante atualização. Esse Sistema agrupa e organiza todo o conhecimento adquirido até hoje sobre os estudos dos solos no Brasil. A classificação pedológica nacional vigente, segundo a EMBRAPA, consiste numa evolução do antigo sistema americano que foi proposto pelos pesquisadores Baldwin em 1938 e modificada por Thorp e Smith em 1949 e foi sendo modificada em decorrência dos diversos estudos realizados por vários pesquisadores sobre os tipos de solo do território brasileiro. Os diferentes tipos de solo são diferenciados segundo sua tonalidade, composição e granulação.

O estudo que originou os dados utilizados nesse trabalho foi realizado na fazenda São Bento, pertencente à Usina São Martinho, em área destinada à produção de cana-de-açúcar, localizada no município de Guariba, São Paulo. As coordenadas geográficas são 21° 24' de latitude sul e 48° 09' de longitude oeste, com elevação média de 550 m acima do nível do mar. O clima da região é classificado como Aw (de acordo com Köppen), tropical de verão chuvoso e inverno seco. A precipitação média é de 1.425 mm, concentrada entre os meses de outubro e março, com 22,2° C de temperatura média anual registrada na região, nos últimos 30 anos.

As áreas utilizadas foram localizadas em dois talhões vizinhos, com diferentes históricos de manejo: cana crua (CC), com sete anos de colheita mecanizada, com grande quantidade de resíduos da cultura sobre a superfície do solo e cana queimada (CQ), com histórico de queima e colheita manual da cultura desde 1970. Deve-se salientar que, anteriormente à conversão para o sistema de cana crua, ambas as áreas apresentavam o mesmo histórico de manejo.

O manejo da cana-de-açúcar no Brasil se dá de duas formas: cana crua, em que o processo de colheita é mecanizado e a cana queimada, onde é realizada a queimada do canavial para a despalha e a cana é colhida manualmente. O manejo de CQ permite o trabalho dos

cortadores no campo, mas envolve aspectos legais, ambientais e econômicos que visam aplicar o método de CC para mecanizar a colheita, com o intuito de dispensar o uso do fogo.

Para apoiar este processo, uma série de programas e legislações estaduais vem sendo estabelecidos, sendo o Protocolo Agroambiental do Estado de São Paulo um dos principais exemplos. Este protocolo foi estabelecido em 2007 e antecipa os prazos legais paulistas para a eliminação da prática da queima, de 2021 para 2014 nas áreas onde já é possível a colheita mecanizada e de 2031 para 2017 nas áreas em que não existe tecnologia adequada para a mecanização. A eliminação da queima visa atender não somente à evolução tecnológica do cultivo de cana-de-açúcar, mas ao comprometimento do setor em reduzir as emissões de CO<sub>2</sub> e outros poluentes. Práticas de manejo dos sistemas de produção agrícola podem afetar a emissão de CO<sub>2</sub> do solo (FCO<sub>2</sub>) e, conseqüentemente, o efeito estufa adicional (SARTORI et al., 2007; LAL, 2009).

De acordo com Are et al. (2009), a operação de queima da cana tem um efeito imediato e direto em propriedades físicas e hidrológicas do solo. E segundo Razafimbelo et al. (2006), Cerri et al. (2007) e Luca et al. (2008) o sistema de cana crua, ou seja, mecanizado, proporciona um retorno dos resíduos vegetais para a superfície do solo, favorecendo assim o acúmulo de matéria orgânica e uma redução na emissão de gases em comparação ao sistema de cana queimada

O controle do plantio de cana-de-açúcar no Brasil é realizado pela União da Indústria de Cana-de-Açúcar (UNICA), organização representativa do setor de açúcar e bioetanol do Brasil, que visa desenvolver as condições para aperfeiçoar o ambiente institucional de modo a favorecer a competitividade do setor sucroenergético no Brasil entre outros.

Segundo a UNICA, a produção de cana-de-açúcar se concentra nas regiões Centro-Sul e Nordeste do Brasil. O Brasil é o maior produtor de cana-de-açúcar do mundo. O País produz mais de 632 milhões de toneladas de cana-de-açúcar por ano (safra 2014/2015) e também é o maior produtor de açúcar do planeta, com 36 milhões de toneladas produzidas e 24 milhões de toneladas exportadas no ciclo 2014/2015, o que corresponde a 20% da produção global e 40% da exportação mundial, respectivamente.

Os dados utilizados nesse trabalho consideraram como período de plantio os anos de 2008, 2010 e 2012, localizados no Estado de São Paulo. Região, que segundo a UNICA, apresentou os respectivos hectares de plantio como mostrado na Tabela 2, e na Tabela 3 são apresentados os respectivos hectares colhidos, verifica-se que o Estado de São Paulo é

responsável por mais da metade da produção nacional tanto de plantio quanto de colheita da cana-de-açúcar.

**Tabela 2 – Produção plantada de cana-de-açúcar no período de realização da coleta de dados.**

<b>ESTADO/SAFRA</b>	<b>2008</b>	<b>2009</b>	<b>2010</b>	<b>2011</b>	<b>2012</b>
São Paulo	4.541.509	4.977.077	5.071.205	5.216.491	5.172.611
<b>Região Centro-Sul</b>	<b>6.905.380</b>	<b>7.610.340</b>	<b>7.895.289</b>	<b>8.336.225</b>	<b>8.482.249</b>
<b>Região Norte-Nordeste</b>	<b>1.305.497</b>	<b>1.235.493</b>	<b>1.269.467</b>	<b>1.280.390</b>	<b>1.270.079</b>
<b>Brasil</b>	<b>8.210.877</b>	<b>8.845.833</b>	<b>9.164.756</b>	<b>9.616.615</b>	<b>9.752.328</b>

Fonte: UNICA / IBGE (2016).

**Tabela 3 – Produção colhida de cana-de-açúcar no período de realização da coleta de dados (em hectares).**

<b>ESTADO/SAFRA</b>	<b>2008</b>	<b>2009</b>	<b>2010</b>	<b>2011</b>	<b>2012</b>
São Paulo	4.530.784	4.781.465	4.986.634	5.205.841	5.150.461
<b>Região Centro-Sul</b>	<b>6.877.409</b>	<b>7.385.248</b>	<b>7.810.665</b>	<b>8.325.574</b>	<b>8.448.817</b>
<b>Região Norte-Nordeste</b>	<b>1.262.680</b>	<b>1.232.307</b>	<b>1.266.041</b>	<b>1.275.742</b>	<b>1.256.571</b>
<b>Brasil</b>	<b>8.140.089</b>	<b>8.617.555</b>	<b>9.076.706</b>	<b>9.601.316</b>	<b>9.705.388</b>

Fonte: UNICA / IBGE (2016).

A conversão de áreas de cana queimada para cana crua representa uma redução significativa na emissão de gases do efeito estufa e também contribui para o aumento, em longo

prazo, nos teores de matéria orgânica do solo, uma vez que os resíduos da cultura que não foram queimados podem ser incorporados ao solo (RAZAFIMBELO et al., 2006; CERRI et al., 2007). Segundo a UNICA, o volume de energia renovável e limpa produzida a partir do bagaço e da palha da cana ofertado à rede em 2014 foi equivalente ao atendimento de aproximadamente 10 milhões de residências, o que evitou a emissão de 8,3 milhões de toneladas de CO<sub>2</sub>. Com a mecanização da colheita em mais de 9,3 milhões de hectares acumulados entre 2007 e 2014, evitou-se a emissão de 34,7 milhões de toneladas de poluentes (monóxido de carbono, hidrocarbonetos e material particulado) e, especificamente, de 5,7 milhões de toneladas de Gases de Efeito Estufa (GEEs) na atmosfera. De acordo com Luca et al. (2008), estima-se que o potencial de sequestro de carbono no Brasil, devido ao manejo sem queima do canavial, seja de 2,6 Tg ano<sup>-1</sup>.

A preocupação com a emissão de CO<sub>2</sub> é de caráter mundial e a agricultura possui um papel importante nesse cenário devido a emissão de CO<sub>2</sub> do solo. No Brasil, as atividades agrícolas, sobretudo as que estão relacionadas às mudanças de uso da terra, são responsáveis por 70% das emissões totais de CO<sub>2</sub> equivalente. Nesse contexto, caracterizar como as práticas de uso e manejo do solo afetam a dinâmica da emissão de carbono ao longo do espaço e do tempo é de grande importância.

De acordo com Brito et al. (2009), a importância da agricultura neste cenário não está relacionada apenas aos processos de perda de carbono do solo via respiração, mas também está relacionada ao seu significativo potencial de mitigação de carbono atmosférico. Dependendo do uso e manejo, os solos agrícolas podem atuar como fontes ou sumidouros de carbono da atmosfera (USSIRI ; LAL, 2009).

O Fluxo de carbono do solo, influenciado pelo uso ou manejo, pode causar impactos na concentração atmosférica de CO<sub>2</sub> (EPRON et al., 2004; SARTORI et al., 2006). Estima-se que, no Brasil, o estoque de C no solo, na profundidade de 0,3 m, seja de aproximadamente 36,4 ± 3,4 PgC. Em adição, mudanças no uso da terra e práticas agrícolas são responsáveis por mais que dois terços do total de gases do efeito estufa emitidos (BERNOUX et al., 2002).

## 5 REDES NEURAIS

A principal motivação para o estudo de redes neurais artificiais é o reconhecimento de que o cérebro processa informações de uma forma inteiramente diferente da realizada por um computador digital convencional. Dados incompletos e inconsistentes podem ser processados pelo cérebro por meio do uso da experiência adquirida, podendo-se afirmar que o mesmo, em muitas situações, é tolerante a falhas (HAYKIN, 1999).

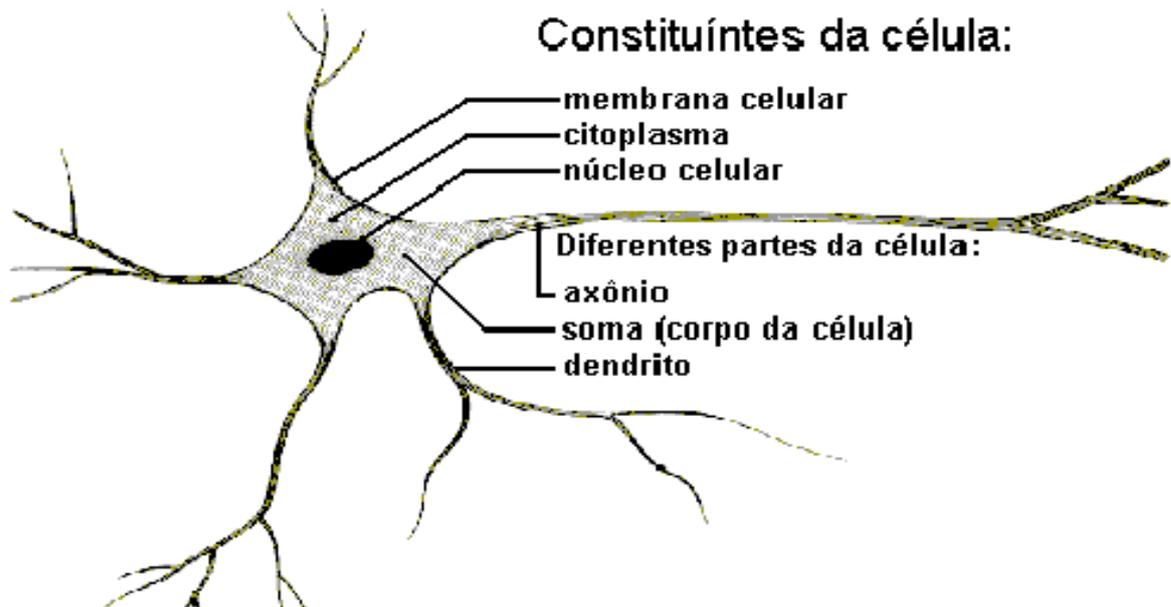
As Redes Neurais Artificiais podem ser consideradas modelos matemáticos que se assemelham às estruturas neurais biológicas e que com o auxílio das ferramentas computacionais, adquirem capacidade de aprendizagem e generalização.

Uma rede neural é composta por diversos neurônios artificiais que são conectados de forma apropriada e assim podem gerar comportamentos interessantes e complexos, determinados pela estrutura das ligações (topologia) e pelos valores das conexões (pesos sinápticos). Um dos modelos de neurônio mais conhecido na literatura especializada é o neurônio de McCulloch e Pitts (McCULLOCH; PITTS, 1943).

### 5.1 Neurônio Biológico

O cérebro humano é composto por bilhões de neurônios, que se encontram interligados numa complexa rede de comunicação. Os neurônios são divididos em três seções: o corpo celular, os dendritos e o axônio, cada qual com funções específicas, contudo tais funções também são complementares. A Figura 7 ilustra o modelo simplificado das partes de uma célula neuronal (KOVACS, 1996).

Figura 7 – Constituintes da célula neuronal.



Fonte: Kovacs (1996).

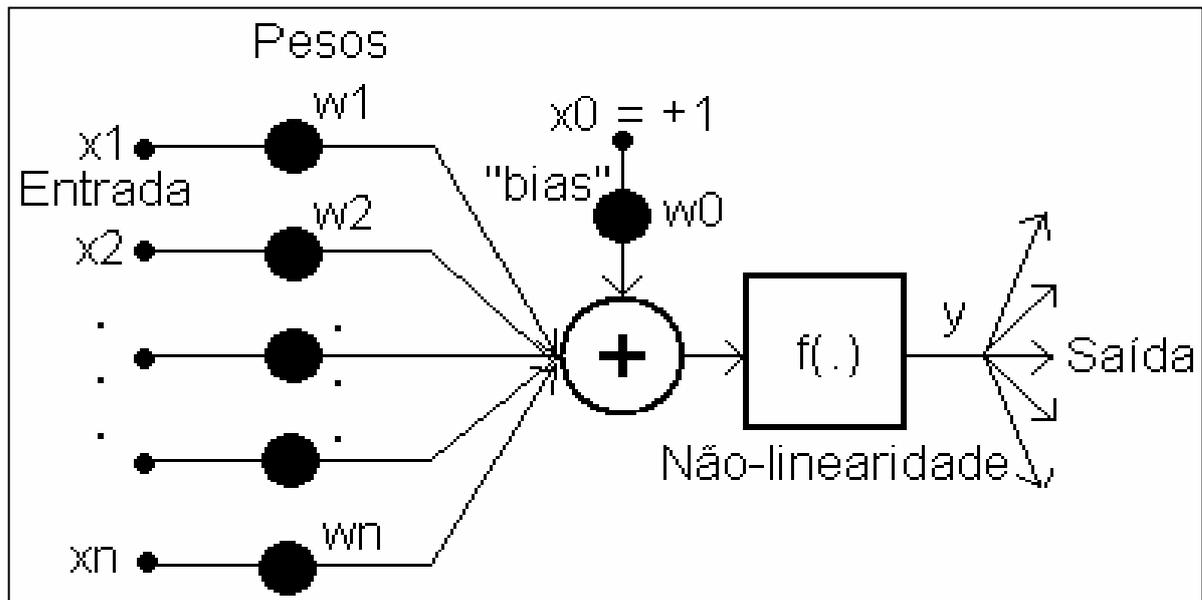
O corpo celular é a parte central do neurônio e é responsável pela recepção e geração dos impulsos nervosos. Os dendritos têm a função de receber as informações, ou impulsos nervosos de outros neurônios e conduzi-las ao corpo celular e o axônio é responsável por conduzir os sinais, processados pelo corpo celular, para os demais neurônios. As sinapses são, os pontos de contato entre a terminação axônica de um neurônio e o dendrito do outro, capazes de controlar a transmissão de impulsos entre os neurônios.

## 5.2 Neurônio Artificial

A busca por um modelo computacional que simule o funcionamento das células do cérebro data dos anos 40, com o trabalho de McCulloch e Pitts (1943). Os dois pesquisadores da área biológica propuseram o primeiro modelo matemático do funcionamento de um neurônio. O modelo por eles apresentado trouxe uma grande contribuição para as discussões sobre o cérebro eletrônico e contribuiu para a criação dos primeiros modelos matemáticos de dispositivos artificiais que buscavam analogias biológicas.

A Figura 8 ilustra o modelo de um neurônio desenvolvido por McCulloch-Pitts (1943), e sua atividade é a soma de “n” entradas ponderadas por seus respectivos “w” pesos. Esta atividade alimenta uma função não-linear  $f(.)$  que produz um sinal que será enviado aos demais neurônios.

Figura 8 – Modelo do neurônio de McCulloch-Pitts.



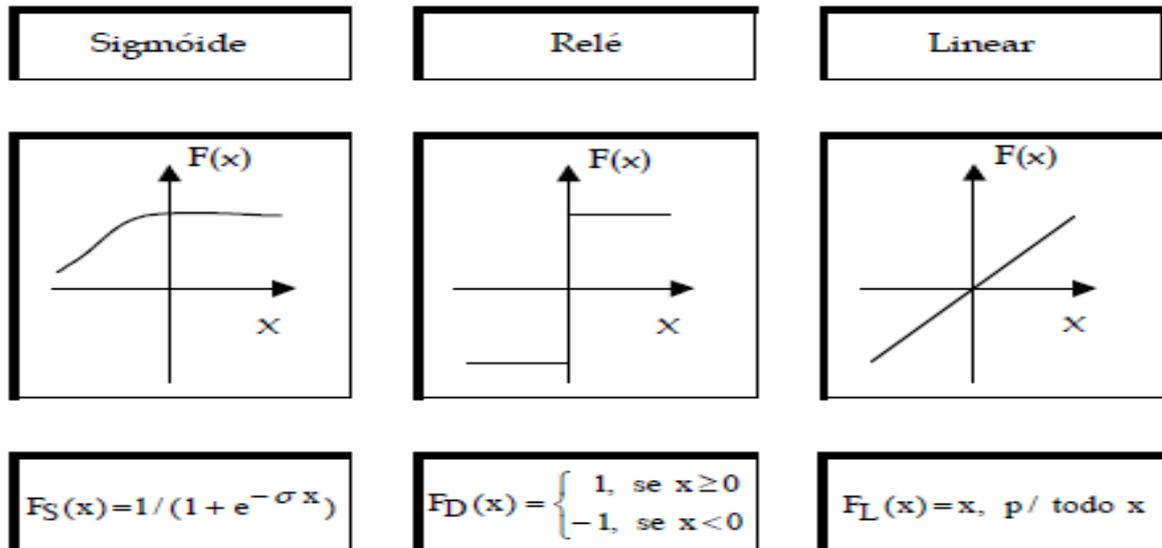
Fonte: Widrow e Lehr (1990).

Este modelo é composto por três elementos:

- um conjunto de  $n$  conexões de entrada ( $x_1, x_2, \dots, x_n$ ), ponderadas por pesos ( $w_1, w_2, \dots, w_n$ );
- um somador (+) para acumular os sinais de entrada; ponderados pelas respectivas sinapses do neurônio (pesos);
- uma função  $f(\cdot)$  de ativação que limita o intervalo permissível de amplitude do sinal de saída ( $y$ ) a um valor fixo.

A ativação do neurônio artificial é feita por uma função denominada função de ativação. A Figura 9 ilustra alguns exemplos de funções de ativação mais empregadas.

Figura 9 – Funções de ativação.



Fonte: Lamothe (1998).

### 5.3 Estrutura das Redes Neurais Artificiais

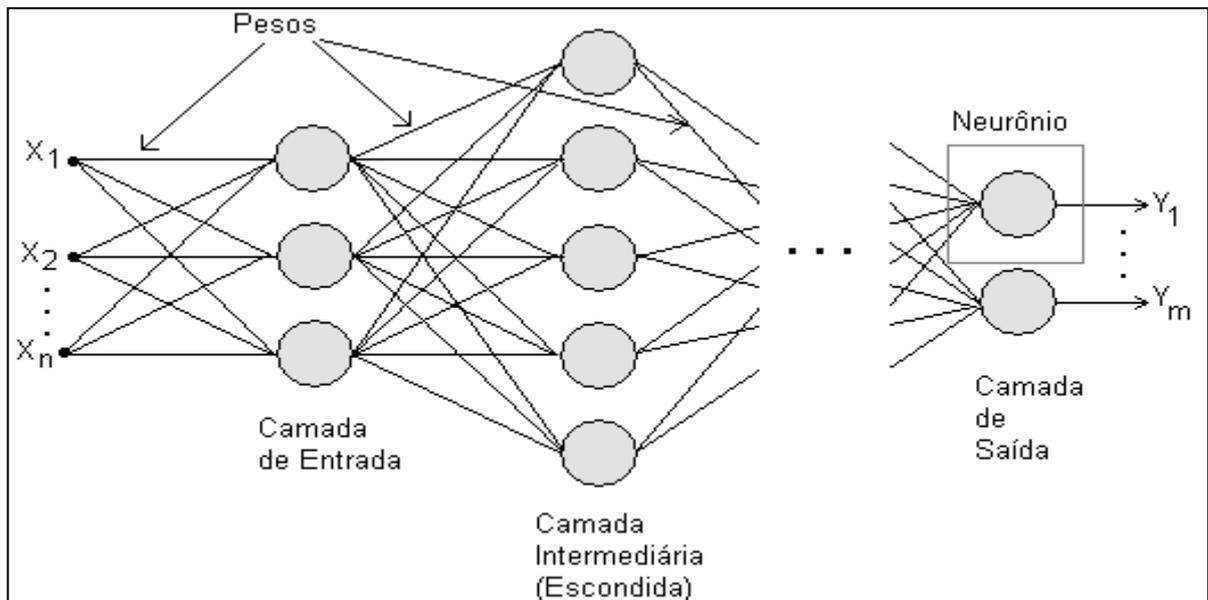
As redes neurais artificiais são modelos que buscam simular o processamento de informação do cérebro humano. São sistemas de processamento de informações formados pela interconexão entre unidades simples de processamento, chamadas de neurônios artificiais. Os neurônios artificiais recebem essa denominação porque foram originados a partir de um modelo matemático de um neurônio biológico. Os neurônios se unem por meio de conexões sinápticas, sendo que a principal propriedade desta arquitetura é a sua capacidade de aproximação universal e de aprendizado.

A maioria dos modelos de redes neurais possui alguma regra de treinamento, na qual os pesos de suas conexões são ajustados de acordo com os padrões apresentados, ou seja, elas aprendem através de exemplos.

As redes neurais têm sua arquitetura, basicamente, organizada em camadas, com unidades que podem estar conectadas às unidades da camada anterior ou posterior. Usualmente, as camadas são classificadas em três grupos: camada de entrada, na qual os padrões são apresentados à rede; camadas intermediárias ou escondidas, nas quais é feita a maior parte do processamento através das conexões ponderadas; e, camada de saída, na qual o resultado final é concluído e apresentado (CARPENTER; GROSSBERG, 1987a).

Uma Rede Neural Artificial consiste de elementos de processamento (neurônios) e suas conexões (sinapses). Cada neurônio pode ter várias entradas, porém somente uma saída. Cada saída pode ser utilizada como entrada a vários neurônios (através de ramificações). Assim, cada neurônio pode receber várias entradas procedentes de outros neurônios. Cada conexão entre neurônios possui um peso que determina sua contribuição na decisão de disparo, controlando, desta forma, os estímulos. A Figura 10 ilustra uma rede neural artificial (WIDROW; LEHR, 1990).

**Figura 10 – Rede neural artificial.**



Fonte: Widrow e Lehr (1990).

Em relação à sua estrutura, as redes neurais podem ser classificadas em dois tipos: redes recorrentes (*feedback*) e redes não-recorrentes (*feedforward*).

As Redes Neurais Recorrentes são assim definidas porque possuem laços de realimentação, ou seja, contém conexões das saídas de uma determinada camada para a entrada da mesma ou de camadas anteriores. As redes que possuem esta estrutura desenvolvem uma memória em longo prazo nos neurônios internos.

As Redes Neurais Não-recorrentes caracterizam-se estruturalmente por estarem disposta em camadas. Nestas redes neurais cada camada de neurônios recebe sinais somente das camadas anteriores, ou seja, elas não possuem laços de realimentação. Esta rede, também chamada de *feedforward* não possui memória, sendo que, sua saída é exclusivamente determinada em função da entrada e dos valores dos pesos.

As redes neurais artificiais se diferenciam pela sua arquitetura e pela forma como os pesos associados às conexões são ajustados durante o processo de aprendizado. A aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre (HAYKIN, 1999).

## 5.4 Treinamento ou Aprendizado

O processo de treinamento é realizado através de ajustes aplicados aos seus pesos, e quando concluído com sucesso, a rede neural atinge uma solução generalizada para uma classe de problemas.

Existem muitos tipos de algoritmos de treinamento específicos para determinados modelos de redes neurais. Eles se diferem pelo modo como os pesos são modificados. Outro aspecto importante é a maneira como a rede neural se relaciona com o ambiente. Existem duas formas básicas de treinamento de redes neurais: o treinamento supervisionado e o treinamento não supervisionado.

### 5.4.1 *Treinamento Supervisionado*

O treinamento supervisionado consiste no ajuste de pesos de uma rede neural para fornecer saídas desejadas, considerando-se o conjunto de padrões de entrada (WIDROW; LEHR, 1990). A rede deve receber um conjunto de entradas padronizadas e seus respectivos padrões de saída. Um dos algoritmos de treinamento supervisionado mais utilizados é o algoritmo retropropagação (*backpropagation*) proposto por Werbos em 1974.

No aprendizado supervisionado a rede neural é treinada com a ajuda de um supervisor, ou seja, de acordo com os dados apresentados na entrada da rede, deverá ser verificado se as saídas são iguais as desejadas. Caso as saídas sejam diferentes das desejadas, então deve-se ajustar os pesos de maneira que a rede armazene o conhecimento almejado. Este processo deve ser repetido com todo conjunto de treinamento, até que o acerto esteja dentro do limite desejado.

### 5.4.2 *Treinamento Não Supervisionado*

O treinamento não supervisionado é aplicado quando não se tem um agente externo que determina a resposta desejada de acordo com os padrões de entrada. Consiste no ajuste de pesos de uma rede neural, levando-se em conta somente o conjunto de padrões de entrada.

Portanto é um procedimento de treinamento auto-organizável ou auto-supervisionado, pois não necessita da saída desejada e não precisa de supervisores para seu treinamento.

No treinamento não supervisionado a rede trabalha as entradas e as organiza de forma a classificá-las, usando para isso seus próprios critérios. Os neurônios são utilizados como classificadores, e os dados de entrada são os elementos de classificação. A auto-organização envolve o processo de competição e de cooperação entre os neurônios da rede.

### 5.4.3 Redes neurais testadas nesse trabalho

Existem diferentes modelos de redes neurais e também de treinamentos, com o intuito de obter o melhor resultado possível, para realização desse trabalho, inicialmente foram propostas algumas metodologias diferenciadas possíveis de serem adotadas para que os resultados fossem ideais, pois diante da grande complexidade, diversidade e dos fatores naturais que apresentam os dados utilizados no trabalho foi necessário analisar qual rede neural corresponderia as expectativas. Para melhor entendimento é apresentado uma breve explicação das redes neurais propostas, dos treinamentos utilizados e com mais profundidade a rede neural utilizada que apresentou melhores resultados.

Neste trabalho, as metodologias propostas foram uma rede neural de múltiplas camadas chamada *Multi Layer Perceptron* (MLP), uma Rede Neural Probabilística (PNN) e uma Rede Neural de Regressão Generalizada (GRNN) e os algoritmos de treinamento *Backpropagation* e *Levenberg-Marquardt*.

#### a) Rede Neural Probabilística (PNN)

A rede neural probabilística (PNN) foi introduzida por Specht (1988), é uma rede de multicamada, *feedforward*, com comportamento estocástico, que permite fazer a associação entre a estrutura da rede e funções de densidade de probabilidades.

A primeira camada de saída que recebe a saída da camada de entrada, é composta de  $mk$  Gaussianas que são computadas para cada classe  $k$  ( $1 \leq k \leq c$ ). A segunda camada escondida calcula a aproximação da função de probabilidade da classe através da combinação de densidades multivariadas e a terceira camada é utilizada para computar a decisão.

A PNN usa as somas das funções gaussianas esféricas centradas em cada vetor do treinamento para estimar as funções da densidade de probabilidade da classe. O treinamento consiste basicamente em ajustar um parâmetro, que é o fator de suavidade  $\sigma$  da curva Gaussiana, sendo este válido para todas as funções Gaussianas da PNN.

As redes PNNs têm um modelamento matemático robusto, são treinadas rapidamente e classificam significativamente bem, comparadas com as redes diretas de múltiplas camadas (Masters 1995). Uma de suas vantagens consiste em que as PNNs possuem um aprendizado rápido, sendo capaz de realizar ótimas classificações. As PNNs com o número suficiente de dados convergem para o Classificador Bayesiano, que é definido como ótimo.

#### b) Rede de Regressão Generalizada (GRNN)

A rede Regressão Generalizada (GRNN), foi proposta por Specht (1991), apresenta um número fixo de camadas, a saber: uma camada de entrada; duas camadas escondidas e uma camada de saída. Seu treinamento é supervisionado, possui uma estrutura do tipo não recorrente e é realizado em apenas uma apresentação dos padrões de treinamento.

Na primeira camada escondida a rede memoriza o treinamento das entradas com as saídas. Por isso, nesta camada tem-se a quantidade de neurônios igual a quantidade de padrões de treinamento. Na segunda camada, existem dois tipos de neurônios, um deles ( $A_i$ ) mede o erro (distância) padrão entre a resposta desejada e a resposta real para o exemplo de treinamento  $i$ . Os demais neurônios do outro tipo ( $B_j$ ) computam a soma dos pesos referentes a cada neurônio representante dos vetores conhecidos, sendo assim a segunda camada tem a finalidade de armazenar as diferenças entre o padrão de treinamento corrente com os padrões armazenados anteriormente e fazer uma interpolação entre eles para gerar uma saída estimada de acordo com o histórico armazenado.

O desempenho da rede é influenciado pelo ajuste dos bias e pelos padrões armazenados. Sendo assim, para um valor de bias muito grande a rede passa a generalizar exageradamente, enquanto que um valor muito pequeno torna a rede incapaz de efetuar a generalização (SPECHT, 1991).

O treinamento da rede GRNN é rápido e feito em um só passo, pois os vetores de entrada são todos copiados para a primeira camada escondida. O intuito é fazer uma associação da função de densidade e probabilidade a partir dos exemplos de treinamento usando estimativa não paramétrica.

Para o treinamento da rede MLP foram utilizados, como já mencionado, os algoritmos *Backpropagation* e *Levenberg-Marquardt*, pois as redes neurais possuem duas fases operacionais. A fase de treinamento determina o aprendizado da rede através das informações dos dados de entrada. Na fase de validação a rede treinada gera uma saída desejada ou estimada. O treinamento é a atividade que conduz a rede ao aprendizado. Denomina-se algoritmo de

aprendizado um conjunto de regras bem definidas para a solução de um problema de aprendizado. O algoritmo determina como os pesos são modificados. A fase de aprendizagem, para uma rede neural, envolve o ajuste destes pesos, de acordo com Dhar e Stein (1997).

O algoritmo de treinamento da rede neural artificial se baseia no procedimento sistemático de adaptação de pesos baseado no método do gradiente descendente, que consiste em adaptar os pesos de tal forma, que o erro quadrático da rede seja minimizado, teoria de Wasserman (1989).

O algoritmo de *Levenberg-Marquardt* é um algoritmo de otimização de parâmetros usado especificamente para a minimização da função de soma dos erros quadrados. O algoritmo é de segunda ordem, ou seja, que utiliza informações sobre a derivada segunda da função para a atualização dos pesos. Segundo Liu (2010), o algoritmo de *Levenberg-Marquardt* propõe uma solução de compromisso entre o algoritmo do gradiente descendente e o método iterativo de Gauss-Newton.

Na rede MLP, com o algoritmo *backpropagation* também foram realizados testes utilizando um filtro passa-baixas com o intuito de filtrar os dados de entrada da rede neural na tentativa de obter-se um melhor acerto.

As redes utilizadas, que apresentam treinamento supervisionado, conseguiram resultados diferenciados e alguns foram satisfatórios na determinação de FCO<sub>2</sub> em áreas de cana-de-açúcar no sistema de cana verde, considerando a diversidade apresentada nos dados.

#### 5.4.4 Redes MLP (*Multilayer Perceptron*)

Entre os diferentes tipos de arquiteturas de rede, o mais comumente utilizado é o *Perceptron* Multicamadas (MLP). Nas redes MLP, cada camada tem uma função específica. A camada de saída recebe os estímulos da camada intermediária e constrói o padrão que será a resposta. As camadas intermediárias funcionam como extratoras de características, sendo que seus pesos são uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação.

O treinamento supervisionado da rede neural MLP, utilizando retropropagação (*backpropagation*), opera em uma sequência de dois passos. Inicialmente apresenta-se um padrão à camada de entrada da rede, a atividade então passa por todas as camadas da rede até obter uma resposta produzida pela camada de saída. Posteriormente, a saída obtida é comparada com a saída desejada. Caso não esteja dentro do desejado, então o erro é calculado, ou seja, o

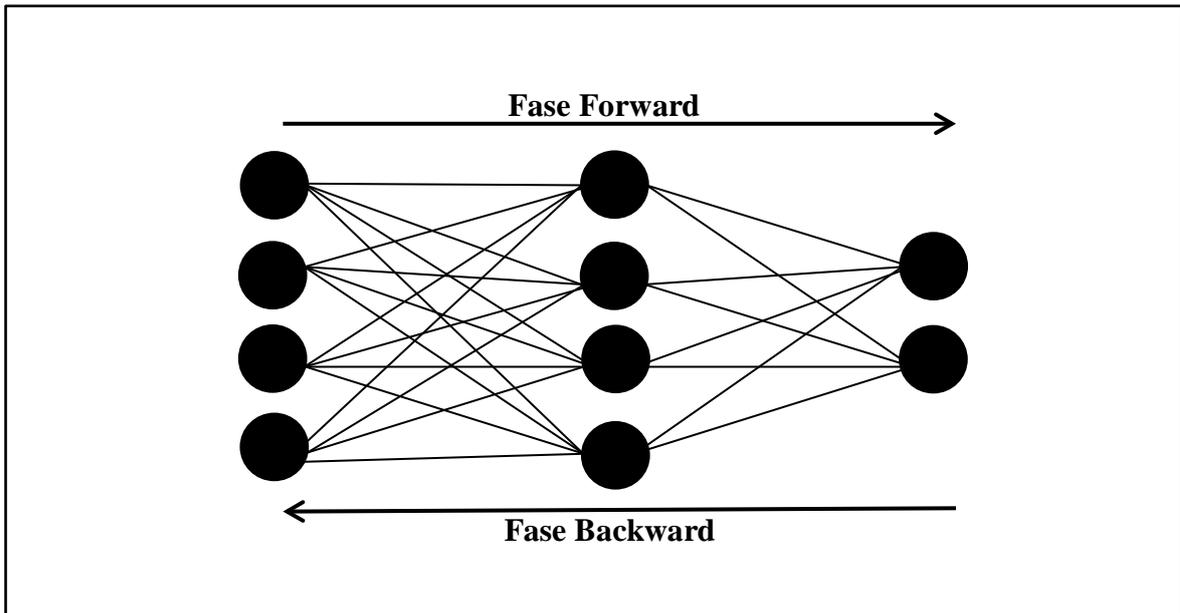
erro é representado pela diferença entre o valor obtido e o valor desejado. O erro então é propagado a partir da camada de saída até a camada de entrada e os pesos das conexões das camadas internas vão sendo alterados à medida que o erro vai sendo retropropagado, com o objetivo de reduzir o erro até um valor aceitável.

Nas unidades de saída, como são conhecidos os valores desejados e obtidos, o ajuste dos pesos sinápticos é relativamente simples e as mudanças nos pesos deverão ser pequenas. Mas para as unidades das camadas ocultas o processo não é tão simples, pois as unidades das camadas ocultas que apresentarem erros grandes devem ter suas conexões bastante alteradas.

O desempenho do algoritmo de aprendizagem retropropagação está relacionado com a modelagem adotada na rede neural artificial e também ao conjunto de dados utilizados no processo de ajuste dos pesos sinápticos entre as conexões da rede.

Werbos (1974) apresentou a primeira concepção do algoritmo retropropagação. Contudo foi somente em 1986 que Rumelhart, Hinton e Williams, idealizaram um modo de como ajustar os pesos de uma rede neural das unidades de entrada para a unidade de saída. Os erros observados nas unidades da camada escondida são determinados pelo erro propagado na direção inversa das unidades da camada de saída. A Figura 11 ilustra o processamento do algoritmo com as fases *forward* e *backward*.

Figura 11 – Fluxo de processamento do algoritmo com as fases *forward* e *backward*.



Fonte: Elaboração da própria autora.

O processo esquemático de adaptação dos pesos através do algoritmo *backpropagation*, Propagação dos Erros, consiste nos passos apresentados a seguir:

1º Passo – Calcular erro na camada de saída;

2º Passo – Determinar o erro nas camadas intermediárias. O erro é dado pela soma dos erros da camada de saída multiplicados pelos pesos das respectivas ligações.

3º Passo – Propagar todos os erros da mesma forma para as restantes camadas intermediárias até a primeira camada.

Após o cálculo dos erros é necessário corrigir os pesos das ligações entre os neurônios segundo o critério de propagação. O cálculo do novo peso é dado pela equação (1).

$$\varpi(k+1) = \varpi(k) + \eta \delta \frac{\gamma f(e)}{\gamma e} y \quad (1)$$

sendo:

$\varpi$  = peso da ligação;

$\eta$  = taxa de treinamento;

$\delta$  = erro calculado;

- $\gamma f$  = derivada da função transferência;
- $y$  = saída do neurônio;
- $k$  = número de iterações.

A rede neural faz a análise de convergência, através do algoritmo retropropagação. Os critérios de parada podem ser estabelecidos por um número predefinido de iterações ou até que se atinja um erro pré-estabelecido (diferença entre a resposta obtida e a esperada), ou seja, o treinamento da rede finaliza-se quando essa diferença for menor que uma determinada margem de erro inicial.

## 6 METODOLOGIA

Neste capítulo, descreve-se o desenvolvimento e a aplicação das Redes Neurais Artificiais utilizadas e os respectivos treinamentos.

### 6.1 Introdução

Os dados utilizados nesse trabalho foram originários de áreas de cana-de-açúcar no sistema de manejo de cana crua (colheita mecanizada) onde os resíduos vegetais (folhas e colmos) foram deixados sob a superfície do solo, de acordo com a Tabela 4. Foram avaliadas a emissão de CO<sub>2</sub>, a temperatura e a umidade do solo, juntamente aos atributos físicos e químicos do solo em gradeados amostrais utilizados para análise geoestatística contendo 89, 141 e 133 pontos amostrais nos anos de 2008, 2010 e 2012, respectivamente (PANOSSO et al., 2012; BICALHO et al., 2014). Os solos de todas as áreas experimentais foram classificados como Latossolo Vermelho eutroférico, textura muito argilosa (SANTOS et al., 2013), Eustrtox (USDA *Soil Taxonomy*). O clima da região como Aw (de acordo com Köeppen), tropical de verão chuvoso e inverno seco. A precipitação média é de 1425 mm (mil quatrocentos e vinte e cinco milímetros), concentrada entre os meses de outubro e março, com 22,2 °C de temperatura média anual registrada na região, nos últimos 30 anos.

**Tabela 4 – Informações geográficas, histórico e período de condução dos estudos nas áreas do estado de São Paulo.**

Município	Coordenadas Geográficas	Tempo de cana crua (anos de conversão)	Período avaliação
Guariba	21° 24' S e 48° 09' O	7	25/10 a 17/11/2008
Guariba	21° 21' S e 48° 11' O	8	14 a 26/07/2010
Pradópolis	21° 20' S e 48° 08' O	15	27/08 a 14/09/2012

Fonte: Panosso et al. (2011).

A emissão de CO<sub>2</sub> do solo foi registrada por meio do sistema LI-COR (LI-8100), em dias subsequentes à operação de colheita mecanizada, durante os estágios iniciais de crescimento das culturas. A temperatura do solo foi monitorada concomitantemente às avaliações de emissão de CO<sub>2</sub>, utilizando-se um sensor de temperatura que é parte integrante do sistema ao LI-8100. A umidade do solo foi determinada por meio de um equipamento de TDR (Time Domain Reflectometry - Hydrosense TM, Campbell Scientific, Austrália).

Após o fim do período de leitura foram coletadas amostras de solo, na profundidade de 0 a 0,10 m. Foram realizadas as seguintes análises de rotina: determinação do teor de matéria orgânica (MO), de P disponível, K, Ca, Mg e H+Al, cálculos da soma de bases e a capacidade de troca de cátions (RAIJ et al., 2001). A densidade do solo foi determinada em amostras indeformadas (EMBRAPA, 1997). O volume total de poros foi, a distribuição de poros por tamanho, macroporosidade e microporosidade foram determinadas utilizando-se funil de placa porosa sob a tensão de 60 cm de altura de coluna d'água (EMBRAPA, 1997).

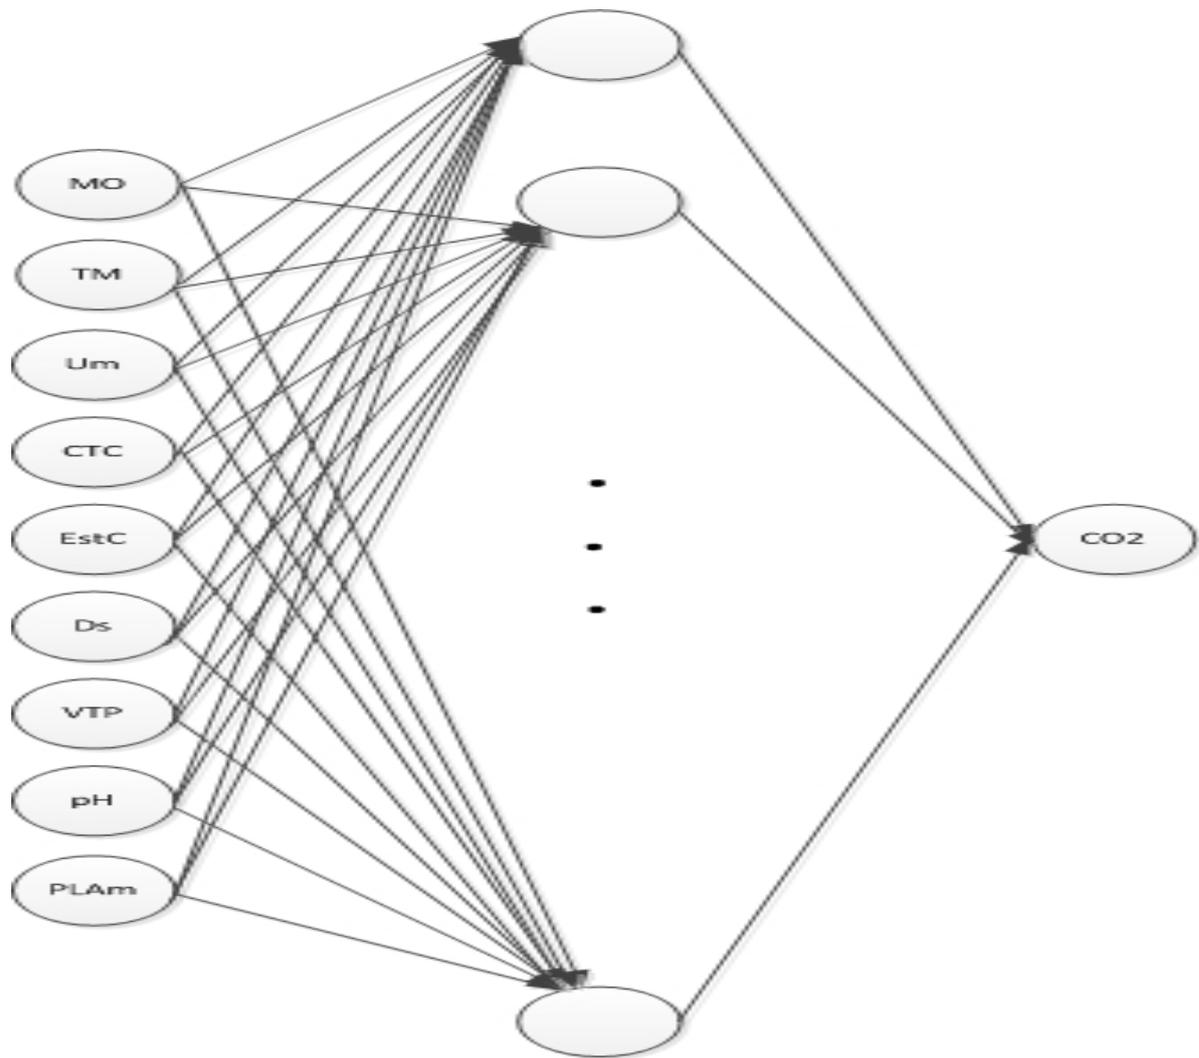
Para a realização da fase inicial deste trabalho, utilizou-se 323 observações registradas nos anos de 2008, 2010 e 2012, as quais foram divididas em dois grupos:

Foram utilizados 197 dados registrados nos anos de 2008 e 2010, os mesmos foram escolhidos aleatoriamente e utilizados para a fase de treinamento da rede neural;

Outros 126 dados registrados no ano de 2012 foram utilizados para a fase de diagnóstico da rede neural, ou seja, classificação da rede neural, isto é, a estimativa de FCO<sub>2</sub>.

A rede utilizada possui três camadas. A camada de entrada foi composta por 9 neurônios, correspondente a entrada da rede. A camada intermediária por 27 neurônios, que foi determinada pela heurística:  $N_I \geq \max \{N_E, N_S\}$ , onde  $N_I$  corresponde ao número de neurônios da camada intermediária,  $N_E$  corresponde ao número de neurônios da camada de entrada e  $N_S$  o número de neurônios da camada de saída (HAYKIN, 1999), no entanto com adaptações do número de neurônios da camada intermediária que melhor corresponderam ao processamento da rede neural. A camada de saída contém apenas um neurônio que corresponde ao diagnóstico da rede neural, ou seja, a emissão de CO<sub>2</sub> do solo. Essa rede está ilustrada na Figura 12.

Figura 12 – Arquitetura da rede neural utilizada processo inicial.



Fonte: Elaboração da própria autora.

As variáveis de entrada da rede neural foram: teor de matéria orgânica (MO), capacidade de troca de cátions (CTC), estoque de carbono (EstC), temperatura média (Tm), umidade média (Um), porosidade livre de água média (PLAm), potencial hidrogeniônico (pH), densidade do solo (Ds) e volume total de poros do solo (VTP).

Para a realização os dados de entrada da rede neural foram normalizados entre [0, 1] com a finalidade de evitar a saturação da rede neural. Foram normalizados seguindo a seguinte heurística: foi determinado o valor máximo apresentado entre todos os valores reais obtidos (medidos), em seguida foi calculado 0,3% do valor máximo, feito isso foi determinada a soma entre o valor máximo e 0,3% do máximo e todos os valores reais foram divididos pelo resultado da soma, variando entre 0 e 1.

Para a estrutura apresentada a metodologia utilizada foi uma arquitetura MLP com o algoritmo *backpropagation*.

Na sequência do trabalho foram retirados da arquitetura da rede duas entradas, capacidade de troca de cátions (CTC) e potencial hidrogeniônico (pH) com o intuito de consolidar os dados obtidos. Sendo assim a rede passou a ter como variáveis de entrada: teor de matéria orgânica (MO), estoque de carbono (EstC), temperatura média do solo (Tm), umidade média do solo (Um), porosidade livre de água média (PLAm), densidade do solo (Ds) e volume total de poros do solo (VTP). A nova estrutura ficou assim composta: a camada de entrada com 7 neurônios, a camada intermediária com 27 neurônios e a camada de saída contém apenas um neurônio.

Para esta nova estrutura apresentada foi novamente utilizada a arquitetura MLP com o algoritmo *backpropagation* e com o algoritmo *Levenberg-Marquardt*. Nesse processo a rede foi treinada utilizando o algoritmo *backpropagation* e depois com os pesos atualizados foi realizado o treinamento utilizando o algoritmo *Levenberg-Marquardt*. Após essa aplicação observou-se que de acordo com as previsões obtidas que este método apresentou uma previsão mais próxima aos pontos de “pico” dos dados reais, sendo assim foi então proposto à aplicação de uma rede dupla, ou seja, uma parte dos dados foram treinados usando o algoritmo *backpropagation* e outra parte utilizou-se o algoritmo *Levenberg-Marquardt*. Ainda com o intuito de obter melhores resultados foi pensado em uma estrutura em duas fases onde a rede inicialmente foi treinada usando o método gradiente descendente e depois, com os pesos atualizados, utilizou-se o algoritmo *Levenberg-Marquardt*.

Sequencialmente foi proposto a mesma estrutura da rede MLP com 100 e com 50 dados na fase de treinamento e os demais utilizados na classificação. Ainda foi proposta a utilização de um filtro passa-baixas para tentar aumentar o índice de acerto, uma rede neural de regressão generalizada (GRNN) e uma rede neural probabilística (PNN) também foram testadas.

O trabalho apresenta os melhores resultados encontrados em todos os testes e metodologias aplicadas. A rede neural MLP com algoritmo *backpropagation* e todas as outras estruturas propostas e apresentadas foram desenvolvidas no MATLAB.

Após a análise dos resultados apresentados no próximo capítulo, decidiu-se utilizar como dados de entrada da rede neural as componentes principais e esses dados foram

trabalhados com auxílio da rede MLP com algoritmo *backpropagation* que apresentou resultados mais satisfatórios.

As variáveis de entrada da rede neural foram determinadas pela análise de componentes principais, que vem sendo muito utilizada na área de ciência do solo, cujo principal objetivo foi identificar, em um conjunto de dados, uma variável que seja capaz de explicar parte significativa da variância, por meio de correlações lineares (MINGOTI, 2005). Segundo Ferreira (2008), a análise de componentes principais é capaz de separar a informação importante daquela redundante e aleatória.

Os componentes principais foram não correlacionáveis, pois possibilitou que o estudo de um problema envolvendo variáveis originais de complexo inter-relacionamento passasse a ser analisado através de um conjunto menor de variáveis não correlacionadas que são as componentes principais. Através da análise das componentes principais foi possível selecionar em uma amostra quais delas possuem quantidade de informação relevante e permitiu compreender o inter-relacionamento entre as variáveis originais.

Para a caracterização dos padrões de variabilidade espacial de FCO<sub>2</sub> nos dados de 2012 (observados e estimados pela rede) foi utilizada a análise do variograma experimental (WEBSTER ; OLIVER, 1990), por meio da estimativa da semivariância, em uma dada distância, tal estimativa foi determinada pela Equação (2):

$$\hat{\gamma}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2 \quad (2)$$

sendo  $h$  a distância de separação entre pares de pontos;  $N(h)$  o número de pares de pontos separados pela distância  $h$ ;  $Z(x_i)$  o valor de FCO<sub>2</sub> no ponto  $x_i$  e  $Z(x_i + h)$  o valor de FCO<sub>2</sub> no ponto  $x_i + h$ .

A escolha do melhor modelo ajustado aos variogramas experimentais (observados e estimados pela rede) foi efetuada por técnicas de validação cruzadas, que consiste na remoção de cada observação pertencente ao conjunto de dados, estimando o seu valor pelo método de interpolação (resultados não apresentados). O modelo escolhido foi aquele que melhor estimou os valores observados, sendo assim, que produziu uma equação de regressão linear entre esses valores, em função dos valores estimados mais próximo da bissetriz – intercepto igual a zero e coeficiente angular igual à unidade (ISAAKS ; SRIVASTAVA, 1989). Os modelos teóricos utilizados são apresentados na Equação (3) a (5):

Modelo Exponencial:

$$\hat{\gamma}(h) = C_0 + C_1 \{1 - \exp[-3(h/a)]\} \quad (3)$$

de forma que,  $h > 0$  ;

Modelo Esférico:

$$\hat{\gamma}(h) = C_0 + C_1 \left[ \frac{3}{2}(h/a) - \frac{1}{2}(h/a)^3 \right] \quad (4)$$

Sendo,  $0 < h < d$  e  $\hat{\gamma}(h) = C_0 + C_1$ , no qual  $h > a$ ;

Modelo Gaussiano:

$$\hat{\gamma}(h) = C_0 + C_1 \left\{ 1 - \exp\left[-3\left(\frac{h}{a^2}\right)\right] \right\} \quad (5)$$

Onde,  $0 < h < d$ , e  $d$  corresponde a máxima distância na qual o variograma foi definido.

Existem três importantes parâmetros no variograma: efeito pepita ( $C_0$ ); patamar ( $C_0 + C_1$ ) e alcance ( $a$ ). O valor da semivariância encontrado na interseção com o eixo Y, simbolizado por  $C_0$ , é definido como efeito pepita e representa a variabilidade de  $\text{FCO}_2$  em distâncias menores do que aquelas amostradas. Idealmente o valor da semivariância deveria ser zero quando a distância de separação  $h$  é zero. Na prática isto geralmente não acontece devido aos erros experimentais e à variabilidade espacial em distâncias inferiores àquelas utilizadas na malha de amostras (WANG et al., 2002). O patamar ( $C_0 + C_1$ ) é o ponto no qual o modelo de variograma atinge o platô e descreve a variação do modelo. O alcance ( $a$ ) é a distância na qual o patamar ocorre e a partir da qual ocorre a independência espacial e não autocorrelação espacial entre as observações. Espera-se que as diferenças de  $Z(x_i) - Z(x_i+h)$  decresçam assim que  $h$  decresça, ou seja, valores de  $\text{FCO}_2$  (observados e estimados) localizados próximos sejam mais parecidos entre si do que aqueles separados por grandes distâncias. Dessa maneira, é de se esperar que aumente com a distância ( $h$ ).

Os parâmetros dos modelos ajustados aos variogramas experimentais foram utilizados na estimativa de  $\text{FCO}_2$  em locais não amostrados, e utilizados na construção de mapas de padrões espaciais a técnica de krigagem ordinária, na Equação (6):

$$Z^*(x_0) = \sum_{i=1}^N \lambda_i Z(x_i) \quad (6)$$

sendo:  $Z^*$  o valor a ser estimado no ponto não amostrado  $x_0$ ;  $N$  o número de valores medidos  $Z(x_i)$  envolvidos na estimativa;  $\lambda_i$  os pesos associados a cada valor medido  $Z(x_i)$ .

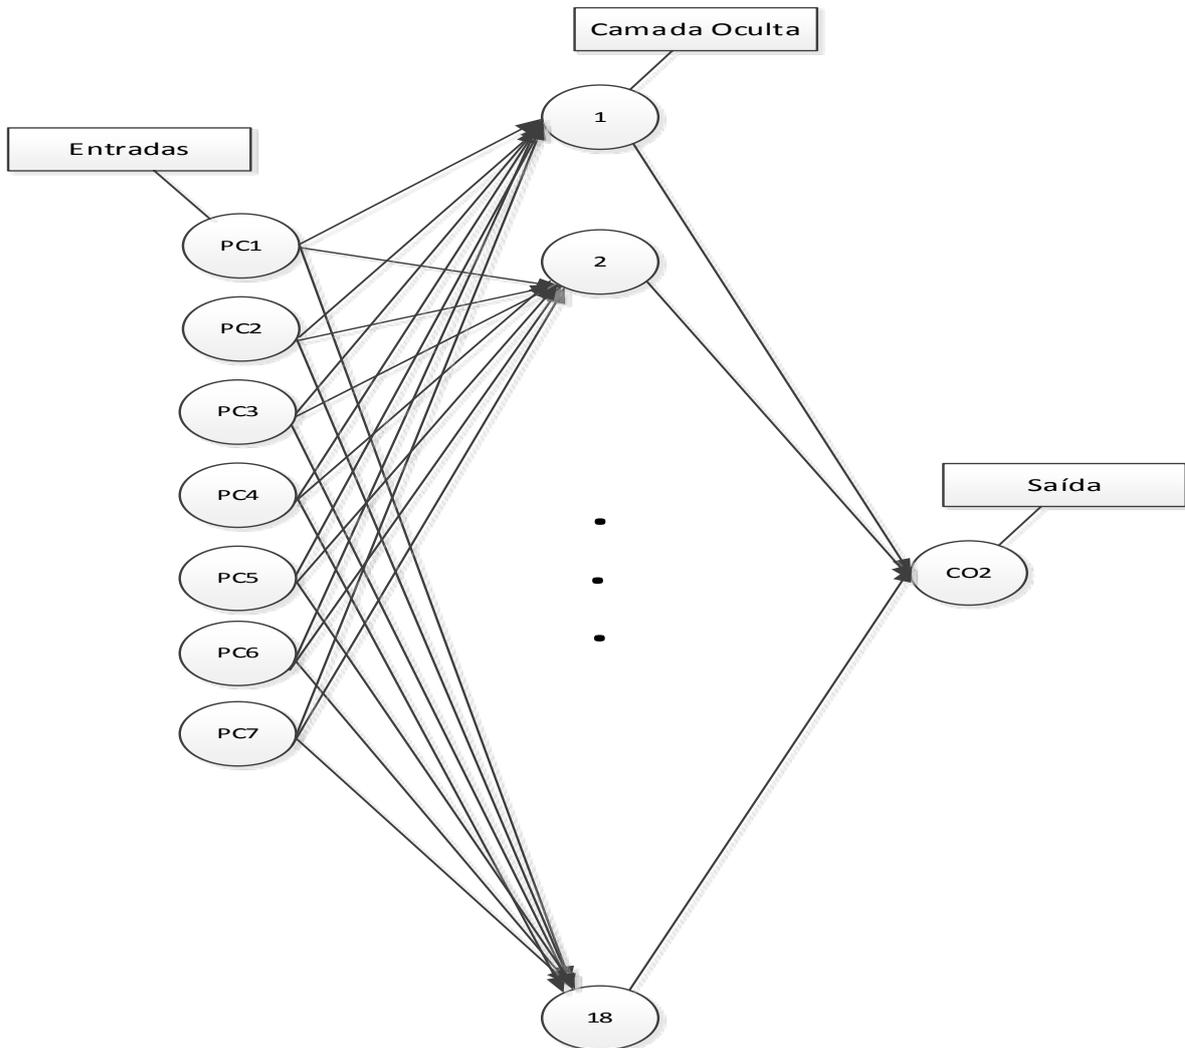
Nesta etapa do trabalho utilizou-se, ao todo, 2377 observações registradas nos anos de 2008, 2010 e 2012, as quais foram divididas em dois grupos:

Foram 1314 dados registrados nos anos de 2008 e 2010 escolhidos aleatoriamente e utilizados para a fase de treinamento da rede neural;

Outros 1063 dados registrados no ano de 2012 foram utilizados para a fase de diagnóstico da rede neural, ou seja, classificação da rede neural, isto é, a estimativa de  $FCO_2$ .

A nova arquitetura neural proposta apresentou sete neurônios na camada de entrada, dezoito neurônios na camada intermediária (oculta) e um neurônio na saída, ilustrada na Figura 13.

Figura 13 – Arquitetura da rede neural utilizada.



Fonte: Elaboração da própria autora.

Considerando as amostras oriundas da área de cana-de-açúcar, as variáveis utilizadas para a composição dos componentes principais foram: teor de matéria orgânica do solo (MO), capacidade de troca de cátions do solo (CTC), estoque de carbono (EstC) do solo, temperatura média do solo (Tm), umidade média do solo (Um), porosidade livre de água média (PLAm), potencial hidrogeniônico (pH), densidade do solo (Ds) e volume total de poros do solo (VTP). Foram determinados os 7 primeiros componentes principais que são (PC1 até PC7) como as respectivas entradas da rede neural utilizada.

Inicialmente, os dados de entrada da rede neural foram normalizados entre [0, 1], seguindo os mesmos procedimentos descritos anteriormente, com a finalidade de evitar a saturação da rede neural.

Para a análise de precisão da emissão de CO<sub>2</sub>, foram definidos o erro percentual absoluto médio (MAPE) e o coeficiente de determinação R<sup>2</sup>, respectivamente, pelas Equações (7) e (8).

$$\text{MAPE} = \frac{1}{N} \{ \sum_{i=1}^N (|ER - EO_{MLP}|) / ER \} \times 100 \quad (7)$$

$$R^2 = \frac{\sum_{i=1}^N (EO_{MLP} - ER_{\text{médio}})^2}{\sum_{i=1}^N (ER - ER_{\text{médio}})^2} \quad (8)$$

em que:

ER é emissão de CO<sub>2</sub> real registrada;

EO<sub>MLP</sub> é emissão de CO<sub>2</sub> obtida pela MLP;

ER<sub>médio</sub> = média da emissão de CO<sub>2</sub> real e

N é número de amostras.

Os parâmetros utilizados pela rede neural artificial MLP na realização do treinamento estão contidos na Tabela 5.

**Tabela 5 – Parâmetros da rede neural MLP e respectivos valores, utilizados para a fase de treinamento e diagnóstico.**

<b>Parâmetros</b>	<b>Aplicação</b>
Número de camadas	3
Número de neurônios por camada	7-18-1
Tolerância	0,009
Taxa de treinamento	0,1
Inclinação da função Sigmóide	0,3

Fonte: Elaboração da própria autora.

## 7 RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados os resultados obtidos com as redes neurais utilizadas durante todo o desenvolvimento do trabalho.

### 7.1 Resultados Iniciais Obtidos

Diante de todas as metodologias aplicadas, na primeira etapa do trabalho descreve-se com mais detalhes a metodologia que apresentou um melhor resultado e os resultados obtidos pelas demais com menos detalhes.

A saída da rede neural MLP é representada pela emissão média de CO<sub>2</sub> do solo. A Tabela 5 apresenta uma pequena amostra do banco de 323 observações e as respectivas saídas obtidas na fase de classificação da rede neural MLP (fase de diagnóstico) com o algoritmo *backpropagation*. As saídas reais são as informações obtidas através dos instrumentos na fase experimental. As saídas obtidas são as informações estimadas por esta rede proposta neste trabalho.

**Tabela 6 – Saídas reais medidas (SRM) e saídas obtidas pela da rede neural MLP (SO) que representam a identificação de emissão de CO<sub>2</sub>.**

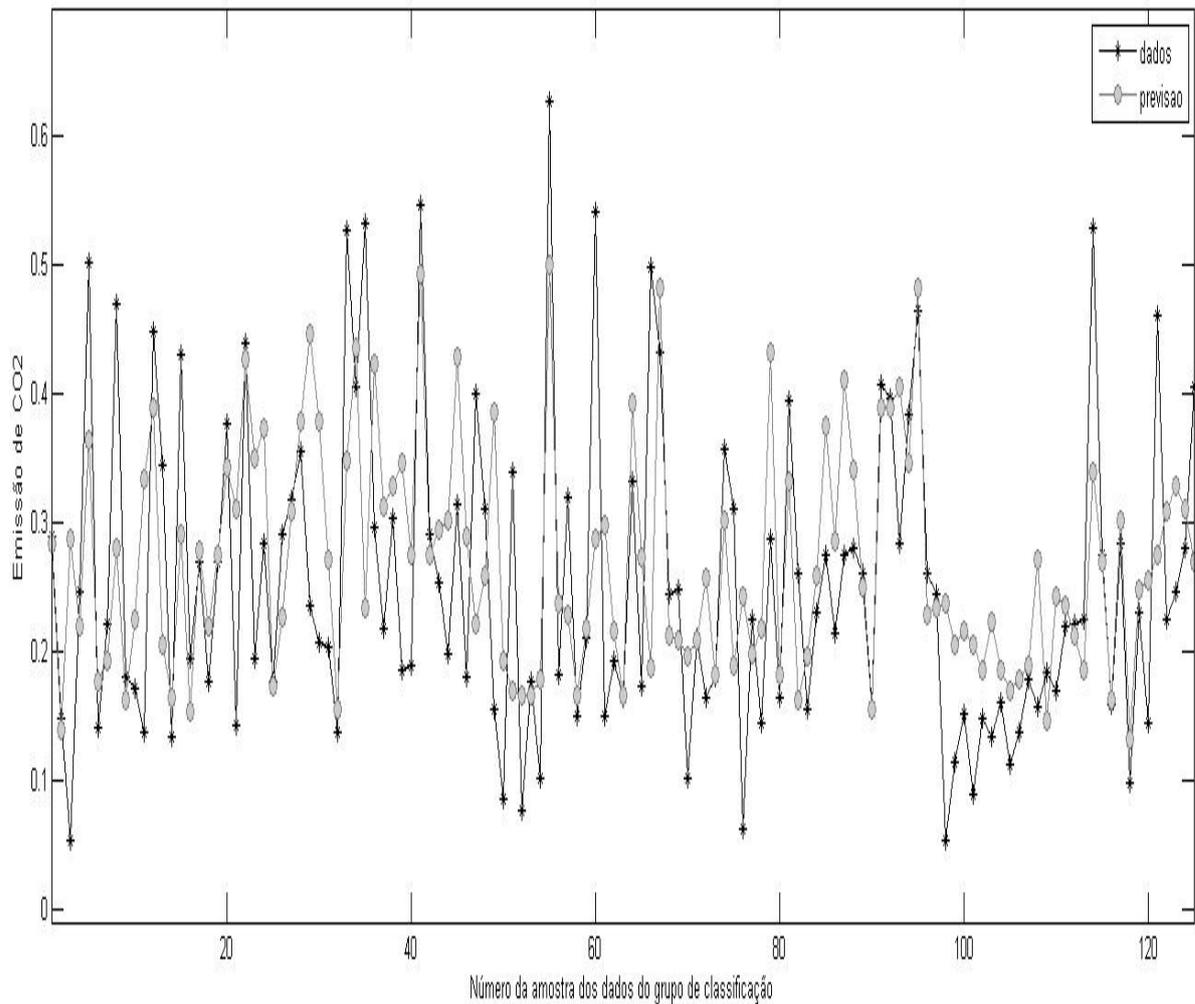
SRM	SO	SRM	SO	SRM	SO
1,122	1,081	0,711	0,782	0,807	0,829
1,194	1,166	0,869	0,930	1,281	1,268
1,353	1,397	0,863	0,795	1,152	1,073
1,301	1,244	1,033	1,078	1,123	1,113
1,222	1,285	1,076	1,036	1,353	1,398
1,045	0,946	1,458	1,423	0,846	0,939
1,184	1,159	0,962	1,050	1,169	1,070

Fonte: Elaboração da própria autora.

A Figura 14 ilustra os resultados obtidos por meio da aplicação rede neural MLP com o algoritmo *backpropagation* e os resultados reais (medidos).

**Figura 14 – Gráfico da previsão da rede MLP (*backpropagation*).**

Rede MLP (*Backpropagation*) com nove entradas

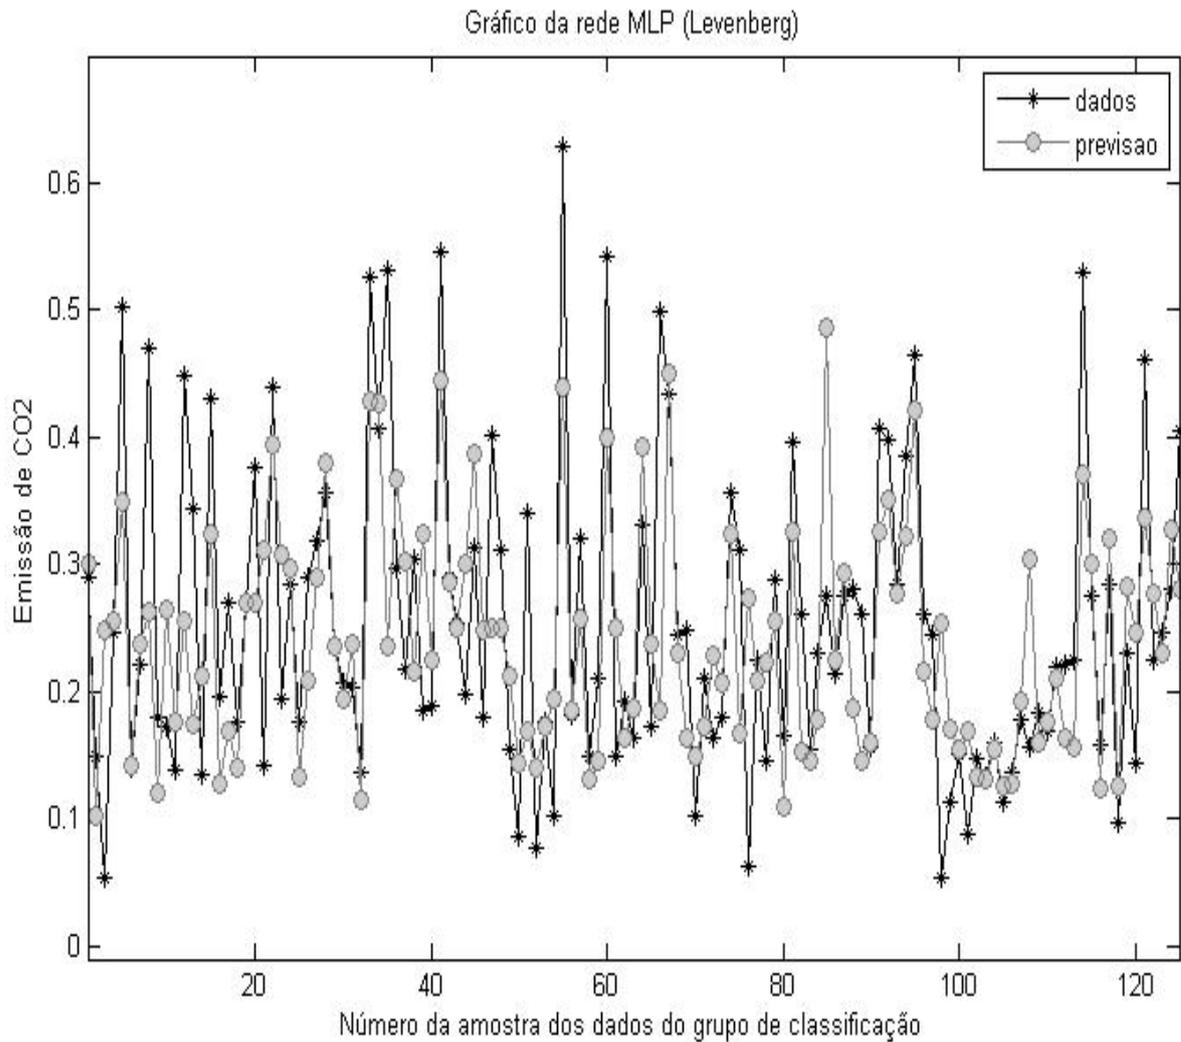


Fonte: Elaboração da própria autora.

A análise de precisão da emissão de CO<sub>2</sub> determinada retratou um erro percentual absoluto médio (MAPE) de 32,2085 e um coeficiente de determinação R<sup>2</sup> de 0,776.

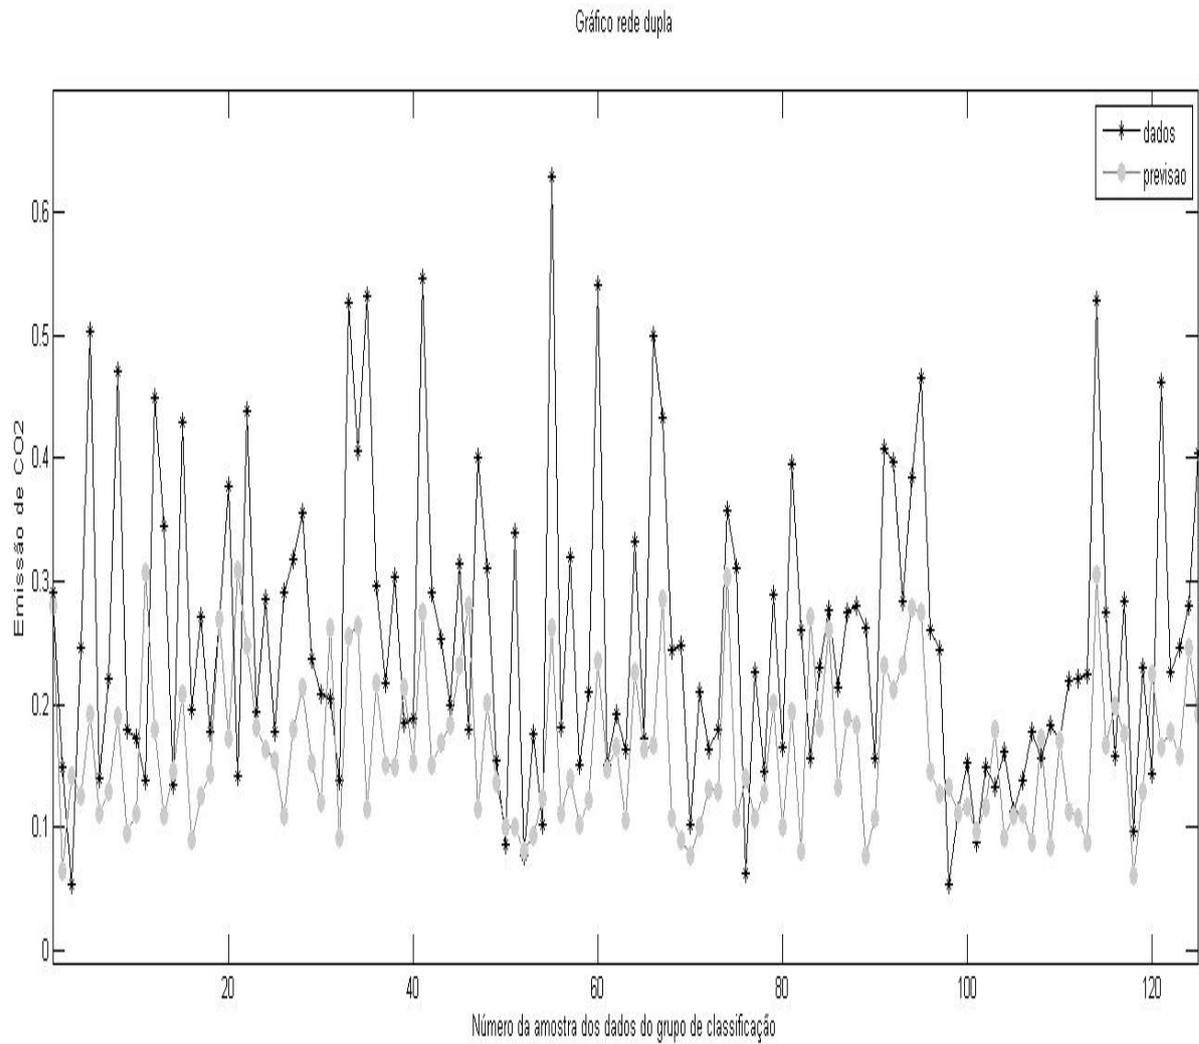
Utilizando a rede MLP com o algoritmo *Levenberg-Marquardt* obteve-se um MAPE de 34,2984, ilustrado na Figura 15.

Figura 15 – Gráfico da previsão da rede MLP (*Levenberg-Marquardt*).



Analisando os desempenhos das redes apresentados nos dois gráficos anteriores aplicou-se uma rede dupla, ou seja, uma parte dos dados foram treinados usando o algoritmo *backpropagation* e para a outra parte utilizou-se o algoritmo *Levenberg-Marquardt*. Com esta estrutura a rede apresentou um MAPE de 41,1451, ilustrado na Figura 16.

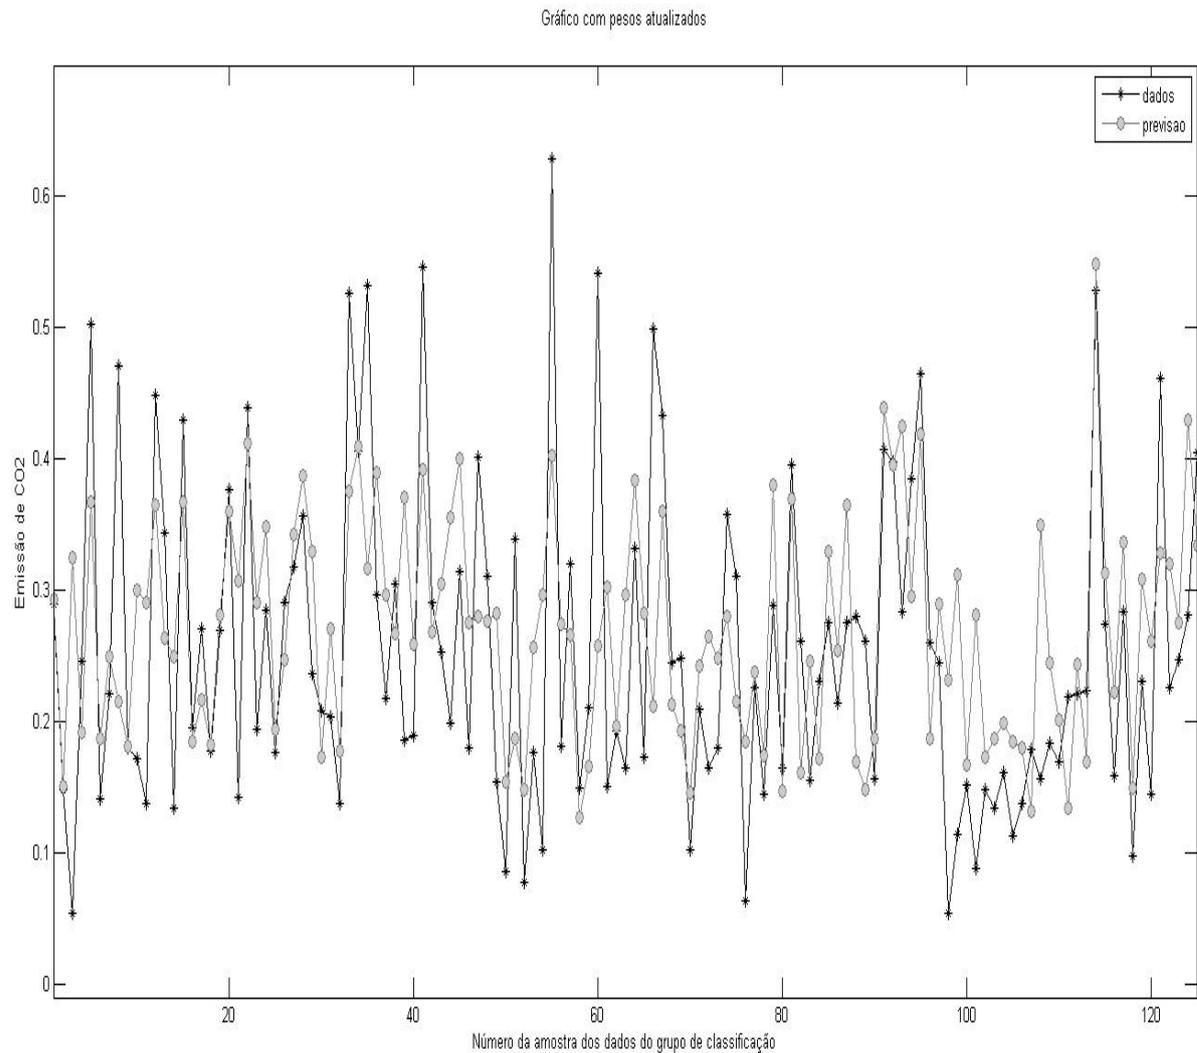
Figura 16 – Gráfico da previsão da rede MLP (*backpropagation e Levenberg-Marquardt*).



Fonte: Elaboração da própria autora.

Para obter melhores resultados foi pensado em uma estrutura em duas fases onde a rede inicialmente foi treinada usando o algoritmo *backpropagation* e depois, com os pesos atualizados utilizando o algoritmo *Levenberg-Marquardt*. A rede apresentou um MAPE de 44,0607, ilustrado na Figura 17.

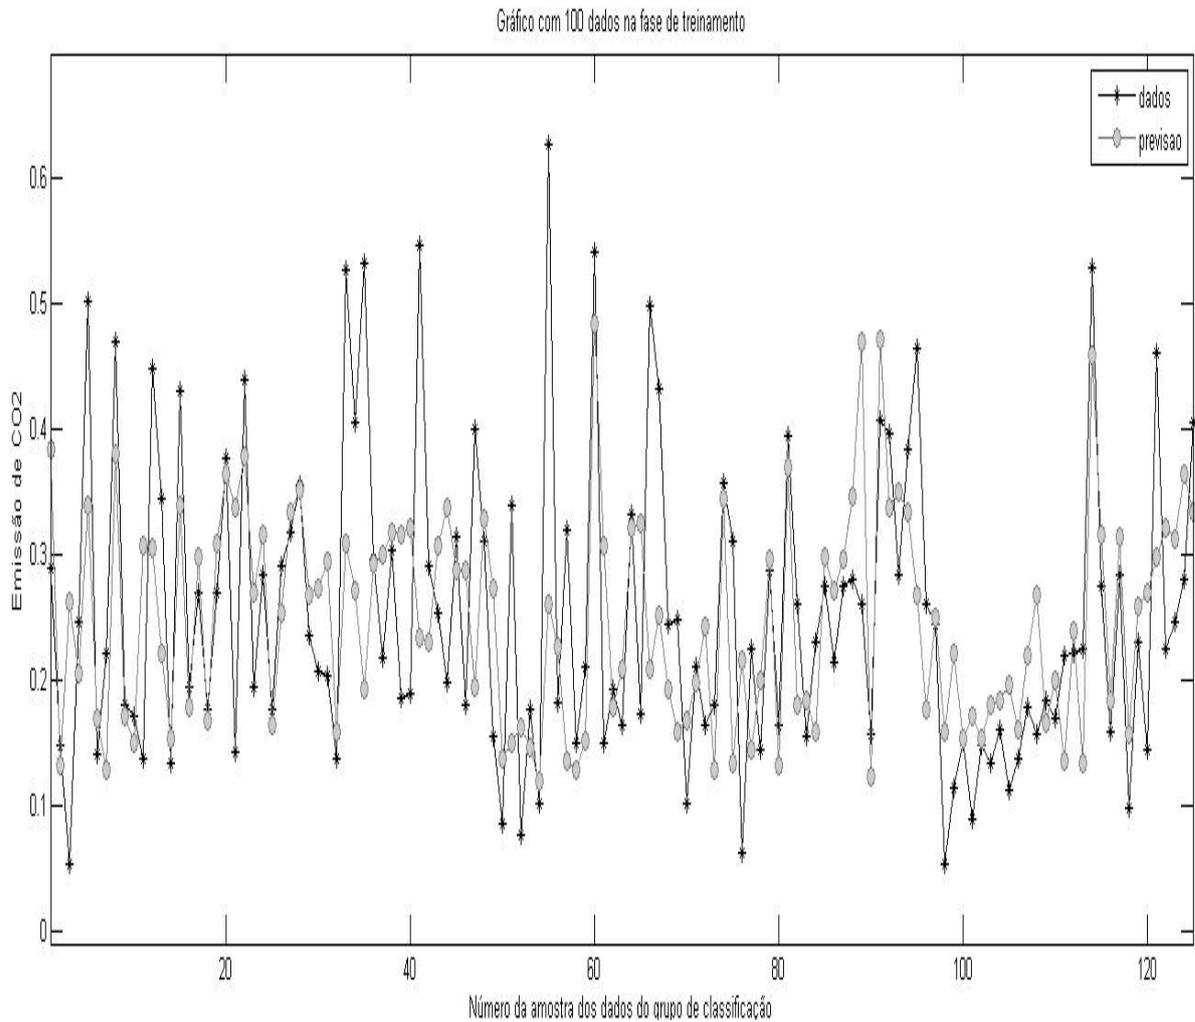
**Figura 17 – Gráfico da previsão da rede MLP (Pesos atualizados).**



Fonte: Elaboração da própria autora.

Sequencialmente foi proposto manter a mesma estrutura da rede MLP com 100 e com 50 dados na fase de treinamento e os demais utilizados na classificação, ilustrados nas Figuras 18 e 19. Os MAPE foram de 38,1159 e 41,8813 respectivamente.

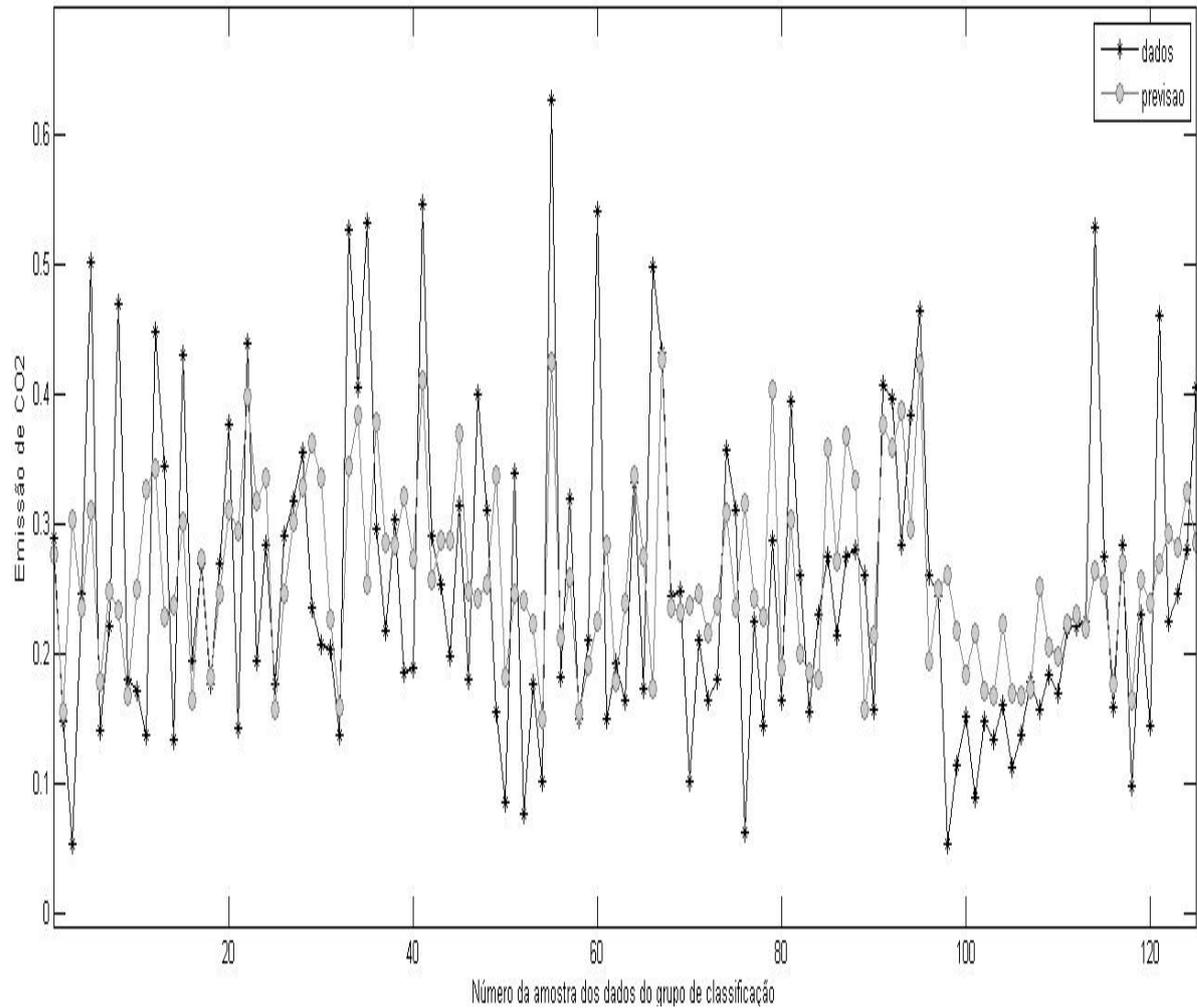
**Figura 18 – Gráfico da previsão da rede MLP (100 dados no treinamento).**



Fonte: Elaboração da própria autora.

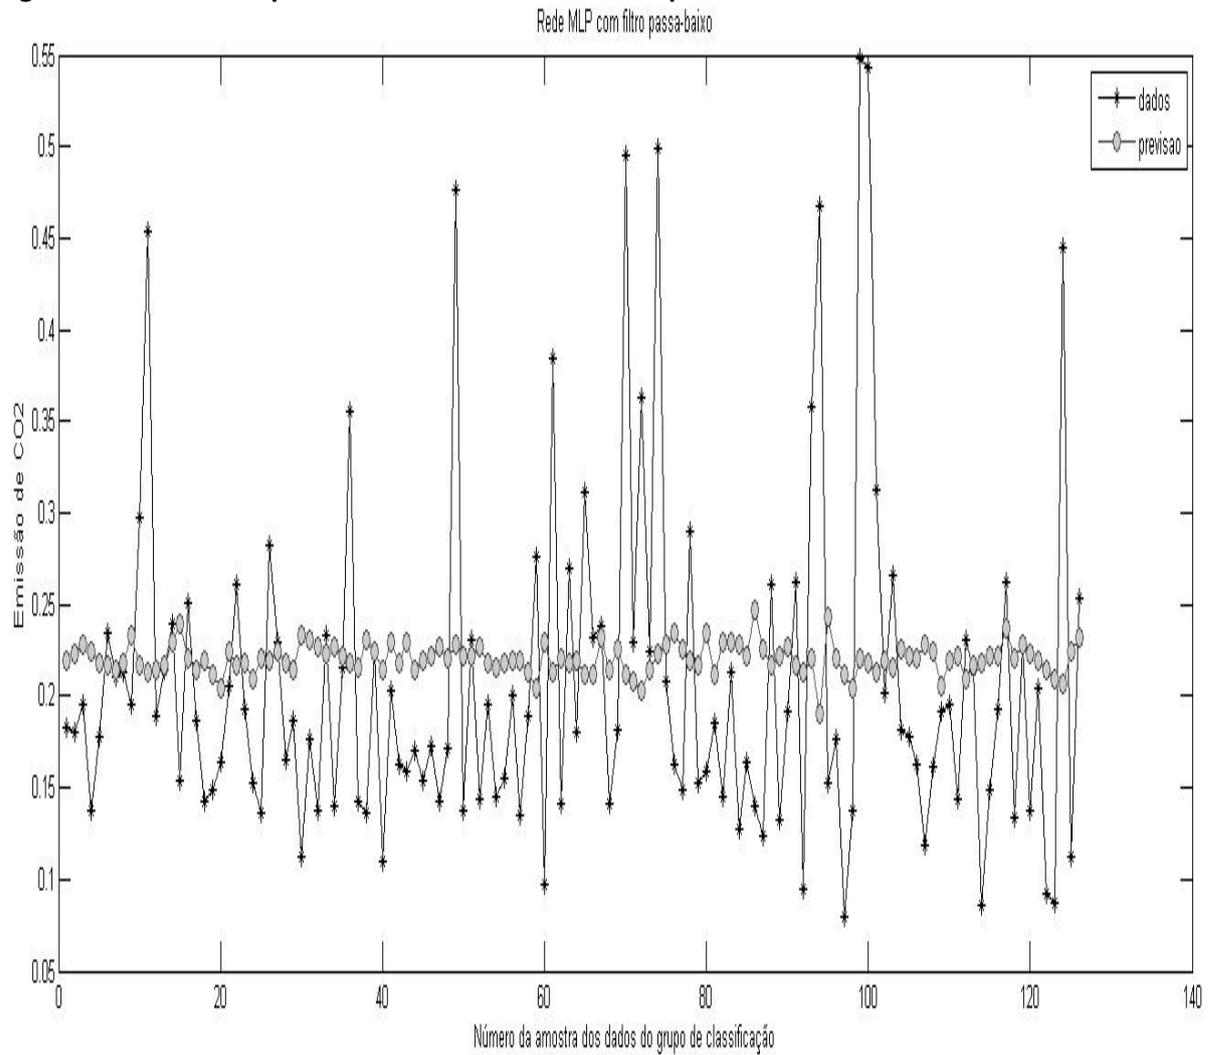
**Figura 19 – Gráfico da previsão da rede MLP (50 dados no treinamento).**

Gráfico com 50 dados na fase de treinamento



Fonte: Elaboração da própria autora.

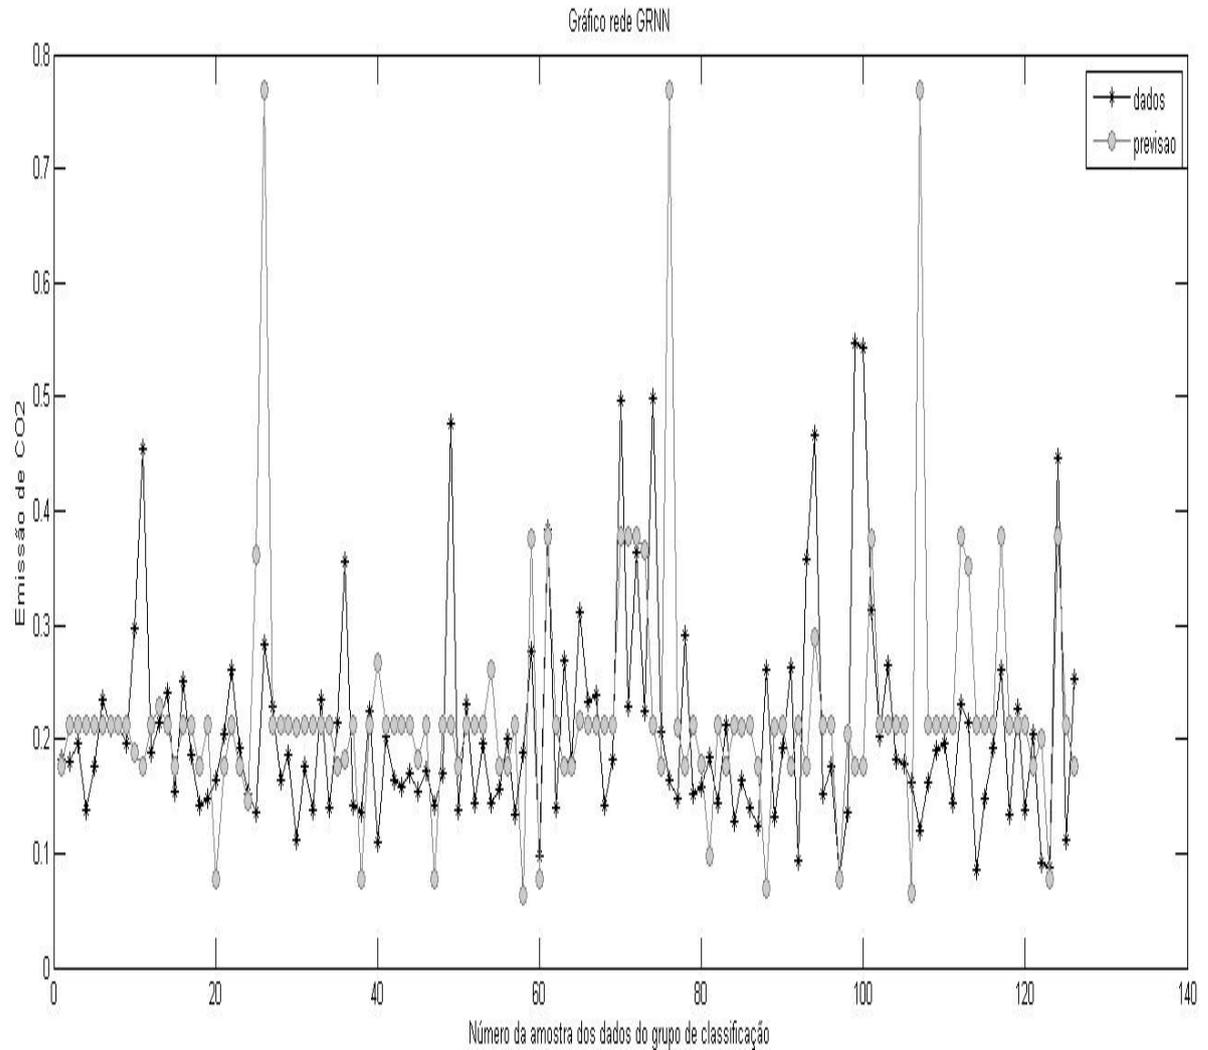
A Figura 20 mostra a utilização de um filtro passa-baixas na rede MLP, onde o MAPE obtido foi de 39,2240.

**Figura 20 – Gráfico da previsão da rede MLP com filtro passa-baixas.**

Fonte: Elaboração da própria autora.

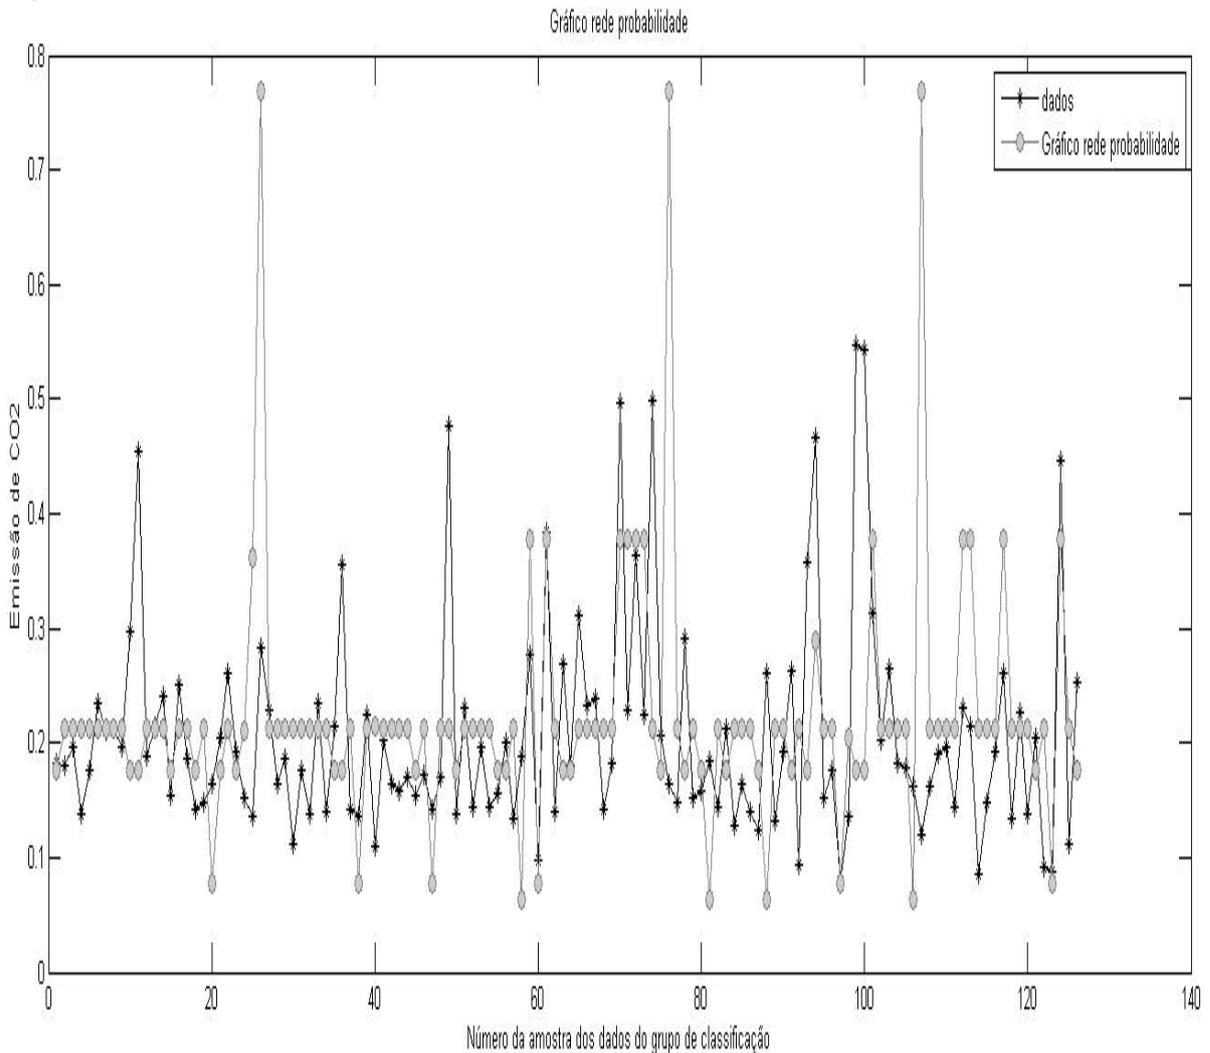
A aplicação da rede neural de regressão generalizada (GRNN) apresentou um MAPE de 43,0225, o gráfico está apresentado na Figura 21.

Figura 21 – Gráfico da rede Neural GRNN.



A Figura 22 ilustra o resultado que a rede neural probabilística (PNN) utilizada apresentou, o MAPE obtido foi de 43,0443.

Figura 22 – Gráfico da rede neural PNN.



Fonte: Elaboração da própria autora.

Para uma melhor visualização dos trabalhos realizados e dos resultados iniciais encontrados, a Tabela 7 apresenta as estruturas das redes neurais testadas e os valores do MAPE e do Erro Máximo alcançados por cada uma delas.

Tabela 7 – Redes testadas e resultados parciais.

<b>Rede Neural</b>	<b>Estrutura</b>	<b>MAPE</b>	<b>Máximo</b>
MLP/ <i>Backpropagation</i>	9-27-1	32,2085	139,0836
MLP/ <i>Levenberg-Marquardt</i>	7-27-1	34,2984	204,4249
MLP/ <i>Backpropagation/Levenberg-Marquardt</i>	7-27-1	41,1451	163,8478
MLP/ <i>Backpropagation/ Levenberg-Marquardt</i> (peso atualizado)	7-27-1	44,0607	504,7235
MLP – <i>Backpropagation</i> - 100 dados entrada	7-27-1	38,1159	390,3607
MLP – <i>Backpropagation</i> - 50 dados entrada	7-27-1	41,8813	466,1180
MLP – <i>Backpropagation/</i> Filtro passa-baixo	7-27-1	39,2240	167,7308
Rede GRNN	7-197-1-1	43,0225	544,7894
Rede PNN	7-197-1-1	43,0443	545,0331

Fonte: Elaboração da própria autora.

Após a análise dos resultados obtidos por todas as metodologias anteriormente mostradas, optou-se então por dar continuidade ao trabalho utilizando a rede neural MLP (*backpropagation*), por ter apresentado um melhor resultado quando comparado com as demais e representar a possibilidade de uma melhor expectativa na melhora dos resultados, com a estrutura apresentada no capítulo anterior.

A rede neural MLP (*backpropagation*) obteve um resultado excelente apresentando um MAPE de 18,2852 e um coeficiente de determinação  $R^2$  de 0,9188. A rede neural foi estruturada com sete neurônios na camada de entrada, dezoito neurônios na camada intermediária e um na saída.

A Tabela 8 apresenta uma pequena amostra do banco de 1063 observações do ano de 2012 e as respectivas saídas obtidas na fase de classificação da rede neural MLP (fase de diagnóstico). As amostras utilizadas (Am) foram comparadas no que tange os dados da saída real medida (SRM) com as saídas obtidas (SO). As saídas reais são as informações obtidas pelos instrumentos na fase experimental. As saídas obtidas são as informações estimadas pela rede proposta neste trabalho.

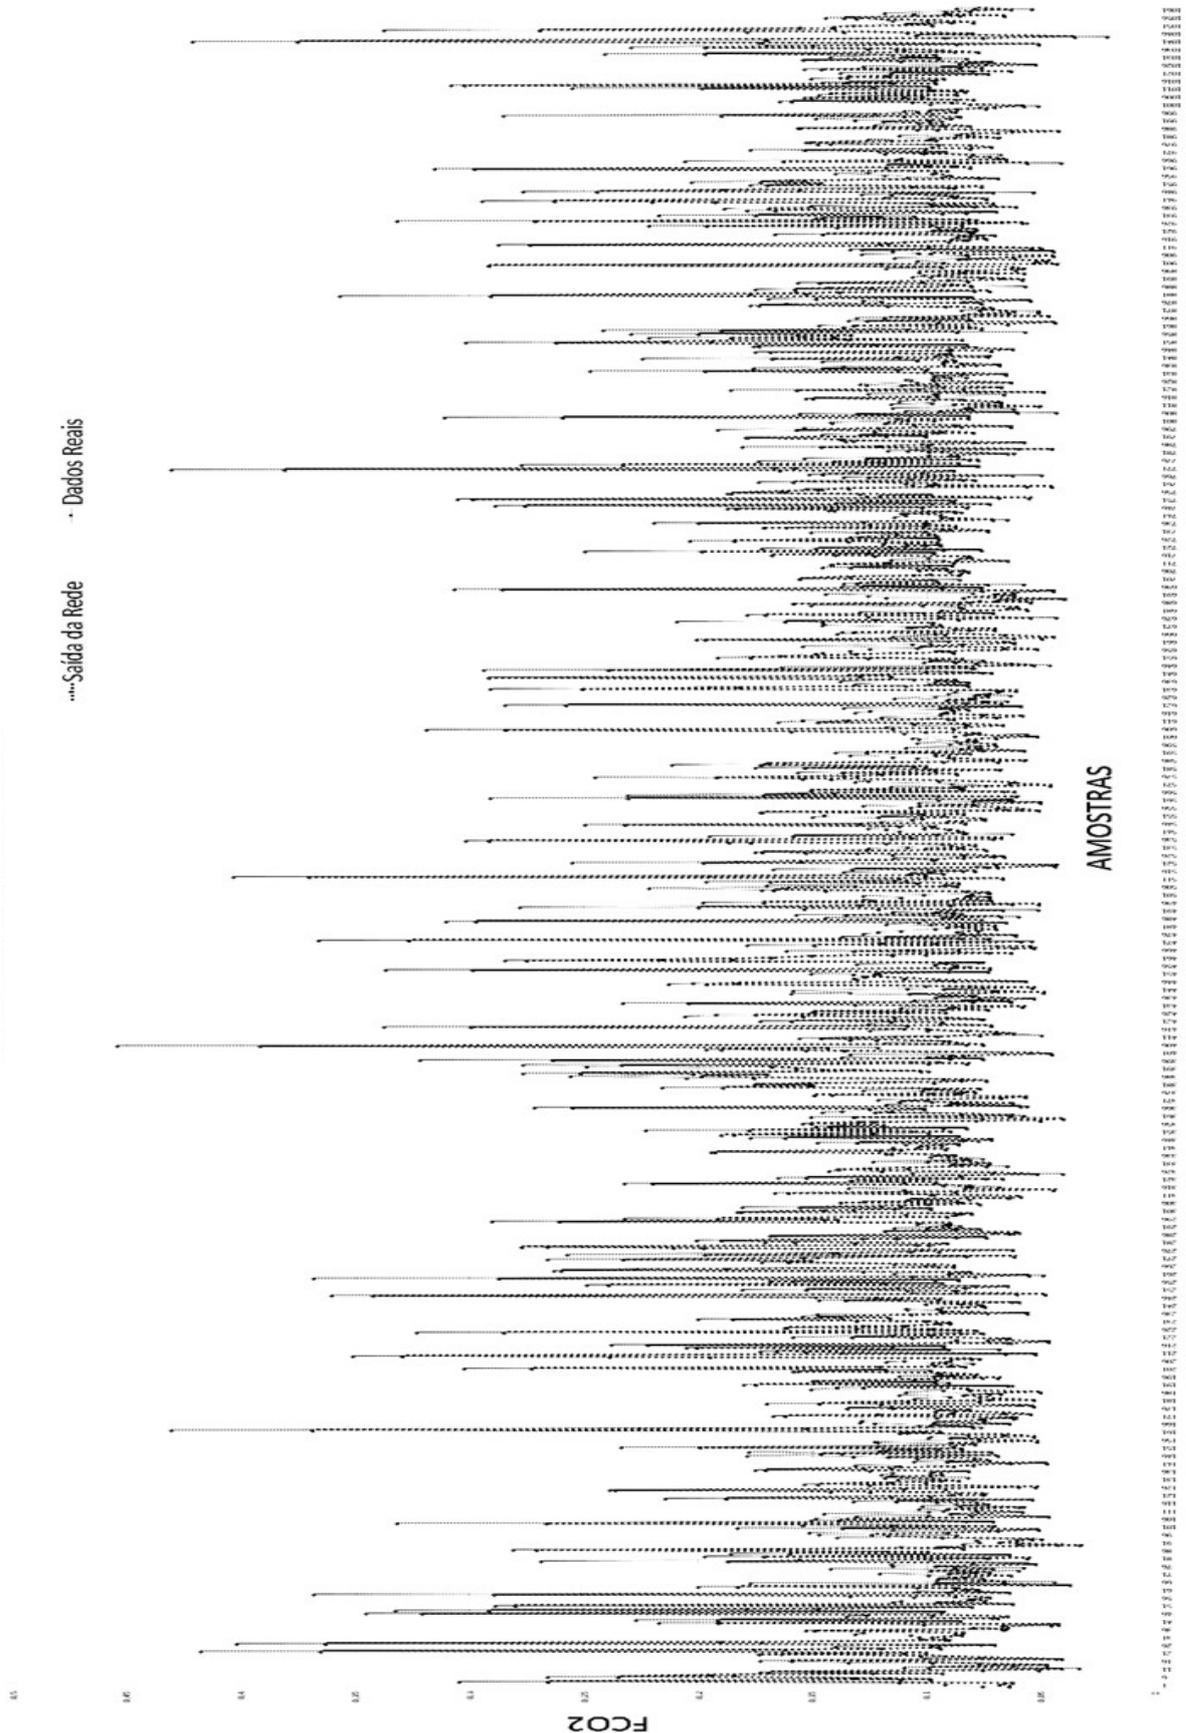
**Tabela 8 – Amostras (Am), saídas reais medidas (SRM) e saídas obtidas pela rede neural MLP (SO) que representam a identificação de emissão de CO<sub>2</sub> do solo.**

Am	SRM	SO	Am	SRM	SO
500	0,126	0,087	510	0,103	0,085
501	0,110	0,071	511	0,195	0,167
502	0,126	0,082	512	0,113	0,108
503	0,100	0,080	513	0,111	0,066
504	0,072	0,072	514	0,402	0,369
505	0,143	0,082	515	0,194	0,099
506	0,171	0,166	516	0,091	0,107
507	0,220	0,160	517	0,135	0,097
508	0,130	0,086	518	0,083	0,078
509	0,169	0,092	519	0,103	0,131

Fonte: Elaboração da própria autora.

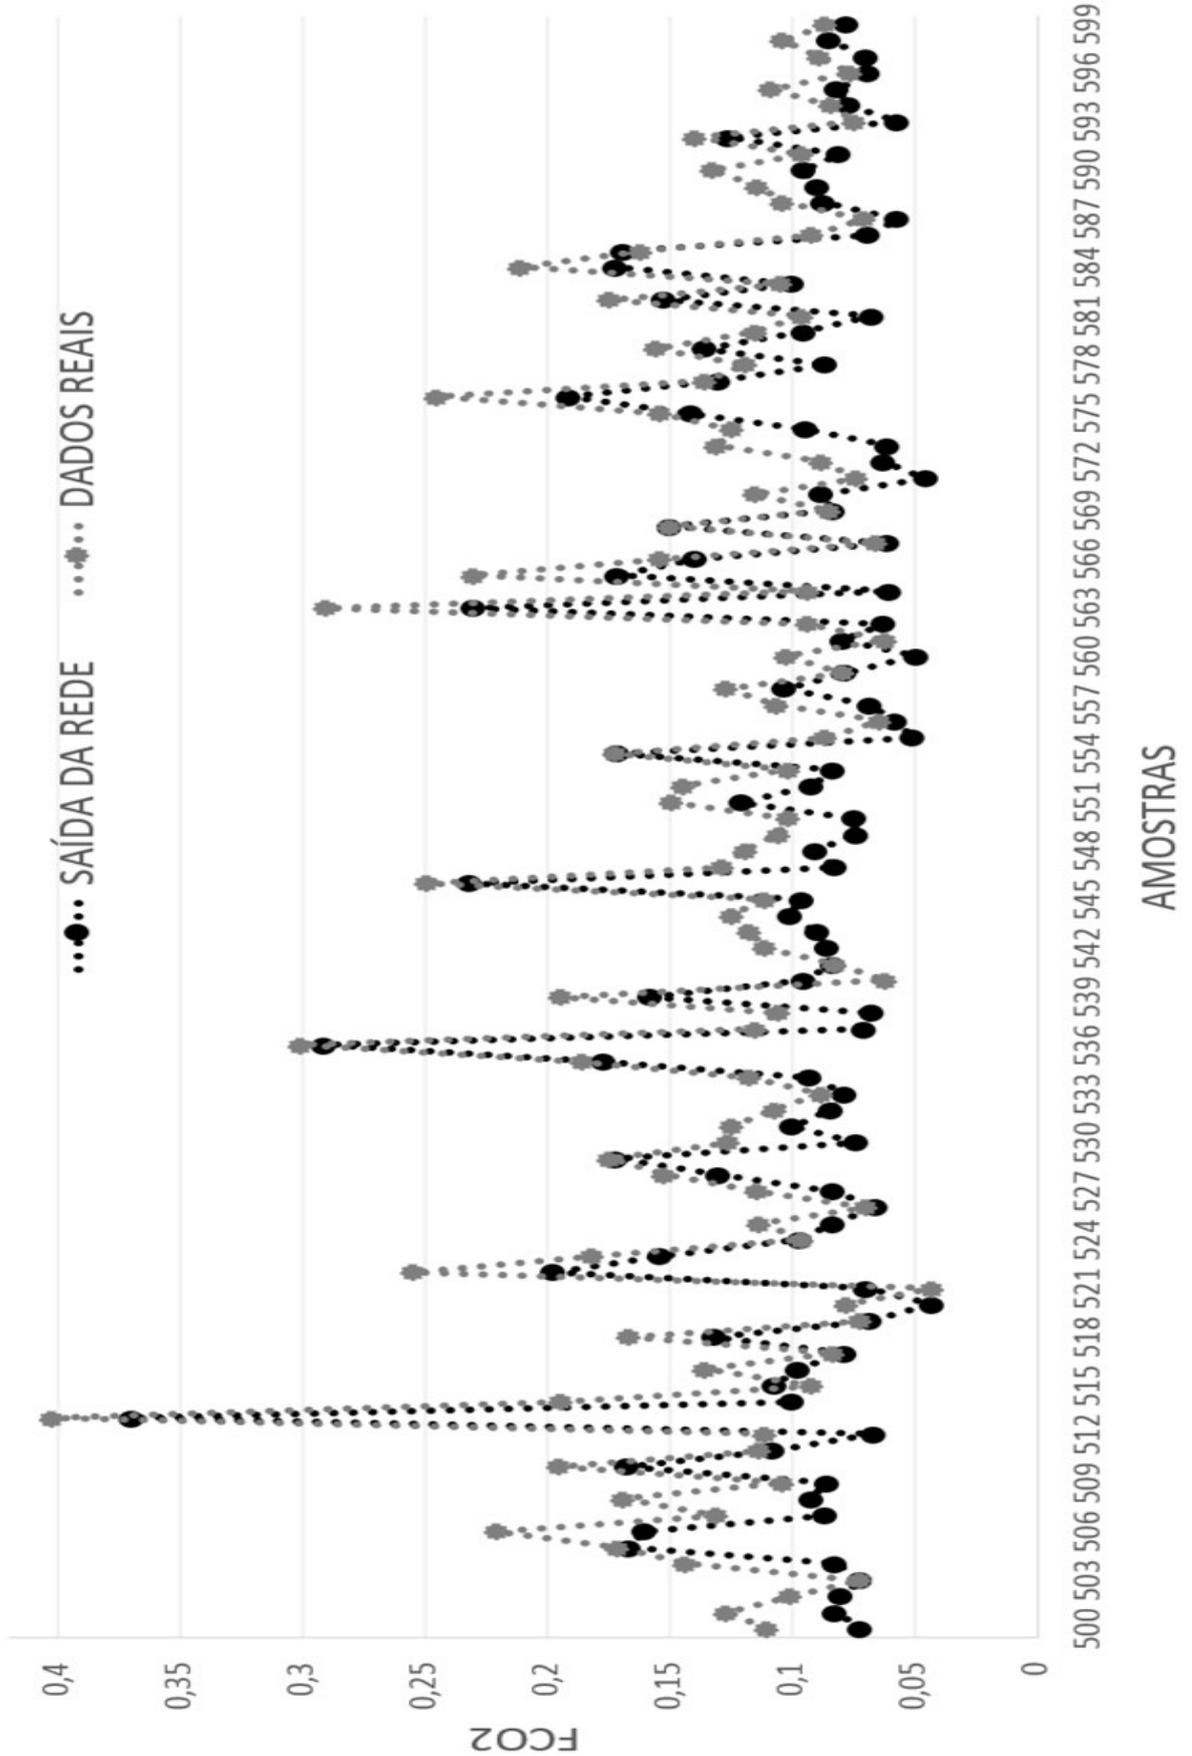
A Figura 23 ilustra os 1063 resultados reais da aplicação e os resultados obtidos pela rede neural, e a Figura 24 ilustra os 100 dados (das amostras número 500 a número 599) com o intuito de facilitar a leitura dos dados e análise do comportamento da rede neural.

Figura 23 – Resultado dos 1063 dados apresentado pela rede neural.



Fonte: Elaboração da própria autora.

Figura 24 – Resultado de 100 dados apresentado pela rede neural.



Fonte: Elaboração da própria autora.

A análise de precisão da emissão de CO<sub>2</sub> determinada retratou um erro percentual absoluto médio (MAPE) de 18,2852 e um coeficiente de determinação R<sup>2</sup> de 0,9188.

A emissão de CO<sub>2</sub> do solo, varia no espaço e no tempo, assim, as estimativas da dependência espacial de FCO<sub>2</sub> para os dias estudados, no ano de 2012, são apresentados na Tabela 9. Os modelos ajustados aos variogramas experimentais de FCO<sub>2</sub> foram, na sua maioria, esféricos, com exceção ao dia 240, primeiro dia de avaliação, cuja estrutura de variabilidade espacial foi descrita pelo modelo Gaussiano. Os valores estimados de emissão de CO<sub>2</sub> do solo, de maneira semelhante, apresentaram sua estrutura de variabilidade espacial descrita, em sua maioria, por modelos esféricos, com exceção aos dias 240 (exponencial), 247 e 251 (Gaussiano). Os valores de alcance (*a*), ou seja, distância de separação onde ocorre a autocorrelação, para os dados FCO<sub>2</sub> observado, variaram entre 8,34 m (dia 255) até o valor de 21,66 m (dia 249). Resultado semelhantes foram observados para os dados de FCO<sub>2</sub> estimados pela rede, onde os valores do parâmetro *a* variaram de 6,34 m (dia 255) até 23,2 m (dia 249).

**Tabela 9 – Modelos e estimativas dos parâmetros ajustados aos variogramas experimentais da emissão de CO<sub>2</sub> do solo (observados e estimados pela rede), nos diferentes dias de avaliação do ano de 2012.**

Dia Juliano	Modelo	C <sub>0</sub>	C <sub>0</sub> +C <sub>1</sub>	a (m)	r <sup>2</sup>
FCO <sub>2</sub> Observado					
240	Gau	0,119	1,197	14,96	0,72
242	Esf	0,066	0,148	11,6	0,75
244	Esf	0,058	0,159	19,98	0,85
247	Esf	0,063	0,150	19,16	0,79
249	Esf	0,113	0,321	21,66	0,86
251	Esf	0,111	0,239	17,27	0,72
255	Esf	0,050	0,128	8,34	0,68
258	Esf	0,052	0,140	17,12	0,80
Média	Esf	0,1179	0,272	18,87	0,67
FCO <sub>2</sub> Estimado					
240	Exp	0,058	0,187	11,10	0,77
242	Esf	0,040	0,123	11,53	0,75
244	Esf	0,059	0,143	20,16	0,73
247	Gau	0,053	0,123	15,32	0,83
249	Esf	0,129	0,260	23,20	0,73
251	Gau	0,116	0,203	13,59	0,75
255	Esf	0,054	0,116	6,34	0,53
258	Esf	0,044	0,114	18,20	0,64
Média	Esf	0,047	0,211	19,32	0,77

*Exp* exponencial; *Esf* esférico; *Gau* Gaussiano; *r*<sup>2</sup> coeficiente de determinação do ajuste do modelo.

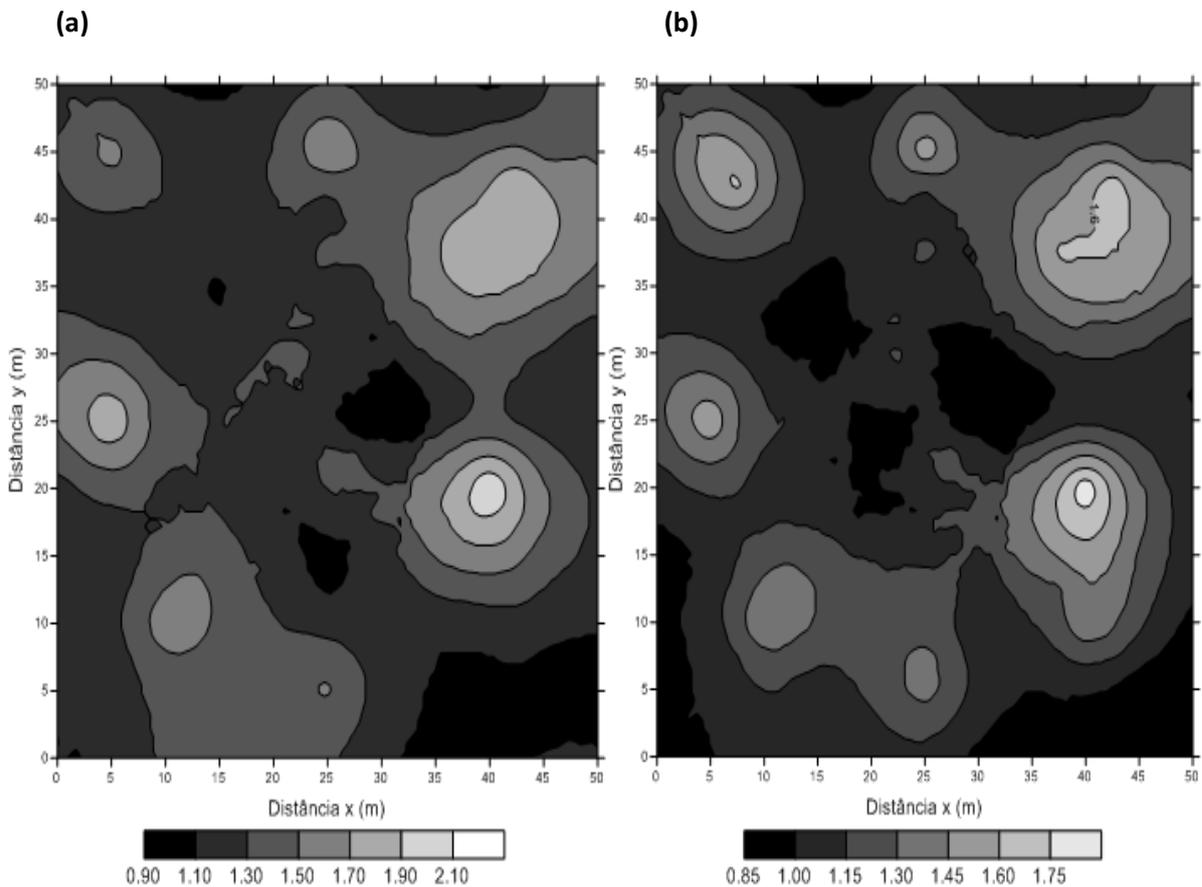
Fonte: Elaboração da própria autora.

Segundo Cambardella et al. (1994) a dependência espacial pode ser avaliada, por meio do coeficiente de efeito pepita (CEP), definida como a razão entre o efeito pepita e o patamar ( $C_0 / C_0 + C_1$ ). Se  $CEP \leq 0,25$  a amostra apresenta alta dependência espacial; se  $0,25 \leq CEP \leq 0,75$  a amostra apresenta moderada dependência espacial e se  $CEP \geq 0,75$  a amostra tem baixa dependência espacial. Segundo Vieira et al. (2000), quanto menor o coeficiente de efeito pepita, maior será a semelhança entre os valores vizinhos e a continuidade do fenômeno, e menor será a variância da estimativa.

Analisando os dados obtidos do FCO<sub>2</sub> observado e do FCO<sub>2</sub> estimado é possível verificar que o coeficiente do efeito pepita apresenta moderada dependência espacial, isto é, a componente aleatória é importante.

A Figura 25 ilustra os mapas do padrão espacial do fluxo de CO<sub>2</sub> do solo. Foi possível observar que os dados apresentam considerável similaridade. Analisando o *grid* é possível notar que os pontos característicos de maior emissão como também os de menor emissão de CO<sub>2</sub> foram identificados pela rede neural, com valores muito próximos.

Figura 25 – Mapas do padrão espacial do fluxo de CO<sub>2</sub> do solo (FCO<sub>2</sub>) observado (a) e estimado (b).



Fonte: Elaboração da própria autora.

## 7.2 Discussão

A rede neural artificial MLP com o algoritmo *backpropagation* apresentada foi a que correspondeu mais satisfatoriamente às expectativas, pois a emissão de CO<sub>2</sub> estimado permitiu com considerável precisão o reconhecimento da situação real que apresentava a área analisada. O MAPE e R<sup>2</sup> apresentados foram considerados satisfatórios sobretudo pelo fato de que os dados analisados pela rede apresentam muita complexidade como descrito anteriormente.

Analisando os resultados obtidos nas diferentes metodologias aplicadas podemos verificar que as previsões variaram entre 18 e 40%, mesmo diante da diversidade dos dados. Ressalta-se que os dados de entrada se referem aos anos de 2008 e 2010 e a rede realizou a

previsão do ano de 2012, por conseguinte há peculiaridades e variações possíveis da natureza. Segundo Panosso et. al. (2011), as propriedades envolvidas nos processos de produção e transporte de CO<sub>2</sub> também possuem grande variabilidade espacial, e a magnitude do FCO<sub>2</sub> varia no tempo e no espaço, dependendo das condições ambientais, das características do solo e do tipo de manejo agrícola adotado. Assim, práticas de manejo podem resultar em modificações nas propriedades físicas e químicas do solo, afetando diretamente a atividade microbiana e, conseqüentemente, a emissão de CO<sub>2</sub> do solo (SARTORI et al., 2006; CERRI et al., 2007)

A rede utilizada conseguiu resultados próximos aos reais na determinação de FCO<sub>2</sub> em áreas de cana-de-açúcar no sistema de cana crua, considerando a diversidade apresentada nos dados e o fato dos mesmos terem sido determinados pelas componentes principais de acordo com o MAPE e o R<sup>2</sup> obtidos.

A rede neural realizou o processo de aprendizagem com dados coletados nos anos de 2008 e 2010 em diferentes meses e dias e classificou os dados coletados no ano de 2012. Mesmo havendo interferência de diversos fatores naturais neste período, essas adversidades não afetaram o aprendizado da rede e a mesma foi capaz de realizar uma previsão bem próxima dos valores reais, o que mostra que a capacidade de aprendizado e adaptação da rede neural foi propícia para o uso em previsões de emissão de CO<sub>2</sub>.

## 8 CONCLUSÃO

Realizar a previsão do FCO<sub>2</sub> com redes neurais artificiais em áreas de cana-de-açúcar pode contribuir significativamente para adequações de manejo do solo para que se reduza a emissão de CO<sub>2</sub> na atmosfera, e assim reduzir o efeito estufa adicional. Além disso, a utilização dessa metodologia pode ser uma ferramenta para a diminuição das incertezas associadas às estimativas dessa importante componente do ciclo do carbono na atmosfera.

Dependendo da natureza da aplicação e da coerência dos padrões dos dados de entrada, em geral, obter-se-á, a priori, treinamento adequado e excelentes estimativas. Assim, essas redes neurais podem ser aplicadas a problemas de relações dinâmicas ou não lineares. Elas suprem uma alternativa analítica que as técnicas convencionais se limitam, muitas vezes, por suposições estritas de normalidade, linearidade, independência de variável, etc.

Os resultados de previsão de FCO<sub>2</sub> obtidos pela rede MLP empregando o algoritmo *backpropagation* estão próximos dos medidos experimentalmente, comprovando uma excelente eficiência da utilização da rede neural artificial na agricultura, assim como as habilidades de adaptação, de aprendizagem e a rapidez de treinamento.

Os resultados mostram um bom potencial desta metodologia para ser aplicada neste tipo de problema. Considerando a aplicação prática, esse resultado pode ser utilizado para auxiliar os profissionais da agricultura e até mesmo nas políticas governamentais de forma que sejam apropriadas e sustentáveis, pois o CO<sub>2</sub> emitido na atmosfera possui grande participação no Efeito Estufa.

A utilização de técnicas de inteligência artificial propiciou estimativas de emissão de FCO<sub>2</sub> muito próximas aos dados reais de 2012, sendo assim, este trabalho apresentou resultados satisfatórios e respondeu as expectativas propostas inicialmente.

Como sugestões para trabalhos futuros, propõe-se uma interferência prática: química e/ou biológica, que possibilite alterações no solo, de acordo com as estimativas determinadas pela rede neural aplicada, com o intuito de reduzir a emissão de CO<sub>2</sub> na atmosfera.

Outra sugestão seria a construção de algum equipamento automatizado capaz de medir as componentes principais do solo, que correspondem as entradas da rede neural.

## 8.1 Publicações

O trabalho realizado intitulado Prediction of the Spatial Variability of Emission of CO<sub>2</sub> Soil in Areas of Sugarcane using Artificial Neural Networks, foi publicado no Intertech 2016, XIV International Conference on Engineering and Technology Education, realizado em Salvador, Brasil.

Outro trabalho intitulado Forecasting Spatiotemporal Variability of CO<sub>2</sub> Emission from Soil in Raw Cane Areas in the Southeast of the State of São Paulo using Artificial Neural Networks foi submetido para o periódico Computers and Electronics in Agriculture.

## REFERÊNCIAS

- ARE, K. S.; OLUWATOSIN, G. A.; ADEYOLANU, O. D.; OKE, A. O. Slash and burn effect on soil quality of an Alfisol: soil physical properties. **Soil & Tillage Research**, Amsterdam, v. 103, n. 1, p. 4-10, 2009.
- BENDER, E. A. **Mathematical methods in artificial intelligence**. New York: IEEE Press, 1996.
- BERNOUX, M.; CARVALHO, M. C. S.; VOLKOFF, B.; CERRI, C. C. Brazil's soil carbon stocks. **Soil Science Society of America Journal**, Madison, v. 66, n. 3, p. 888-896, 2002.
- BICALHO, E. S.; PANOSSO, A. R.; TEIXEIRA, D. D. B.; MIRANDA, J. G. V.; PEREIRA, G. T.; LA SCALA, N. Spatial variability structure of soil CO<sub>2</sub> emission and soil attributes in a sugarcane area. **Agriculture Ecosystems & Environment**, Amsterdam, v. 189, p. 206-215, 2014.
- BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDEMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000.
- BRASIL. Ministério da Ciência e Tecnologia. Coordenação-Geral de Mudanças Globais de Clima. **Comunicação Nacional inicial do Brasil à convenção-quadro das Nações Unidas sobre mudança do clima**. Brasília: Ministério da Ciência e Tecnologia, 2004.
- BRIMBLECOMBE, P. **Air composition & chemistry**. 2. ed. Cambridge: University Press, 1996, 253 p.
- BRITO, L. F.; MARQUES JÚNIOR., J.; PEREIRA, J. T.; SOUZA, Z. M.; LA SCALA Jr., N. Soil CO<sub>2</sub> emission of sugarcane field as affected by topography. **Scientia Agricola**, Piracicaba, v. 66, n. 1, p. 77-83, 2009.
- CAMBARDELLA, C. A.; MOORMAN, T. B.; NOVAK, J. M.; PARKIN, T. B.; KARLEN, D. L.; TURVO, R. F.; KONOPA, A. E. Field-scale variability of soil properties in central Iowa soils. **Soil Science Society of American Journal**, Madison, v. 58, n. 5, p. 1501-1511, 1994.
- CANADELL, J. G. et al. Contributions to accelerating atmospheric CO<sub>2</sub> growth from economic activity, carbon intensity, and efficiency of natural sinks. **Proceedings of the National Academy of Sciences**, Washington, v. 104, p. 1866-18870, 2007.
- CARPENTER, G. A.; GROSSBERG, S. A. Massively parallel architecture for a self-organizing neural pattern recognition machine. **Computer Vision, Graphics and Image Processing**, New York, v. 37, n. 1, p. 54-115, 1987a.
- CERRI, C. E. P.; SPAROVEK, G.; BERNOUX, M.; EASTERLING, W. E.; MELILLO, J. M.; CERRI, C. C. Tropical agriculture and global warming: Impacts and mitigation options. **Scientia Agricola**, Piracicaba, v. 64, p. 83-99, 2007. Disponível em: <<http://dx.doi.org/10.1590/S0103-90162007000100013>>. Acesso em: 12 jan. 2016.
- DHAR, V.; STEIN, R. **Seven methods for trans-forming coporate data into ussines intelligence**. New Jersey: Prentice Hall, 1997. p. 77-106.

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária. Centro Nacional de Pesquisa de Solos. **Manual de métodos de análise de solo**. 2. ed. Brasília: Ministério da Agricultura e do Abastecimento, 1997. 212 p.

EMBRAPA – Empresa Brasileira de Pesquisa Agropecuária. **Sistema brasileiro de classificação de solos**. 2.ed. Rio de Janeiro: Embrapa Solos, 2006. 306 p.

EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária. Centro Nacional de Pesquisa de Solos. **Manual de métodos de análise de solo**. 2. ed. Brasília: Ministério da Agricultura e do Abastecimento, 2013.

EPRON, D.; NOUVELLON, Y.; ROUPSARD, O.; MOUVONDY, W.; MABIALA, A.; SAINT-ANDRÉ, L.; JOFFRE, R.; JOURDAN, C.; BONNEFOND, J.; BERBIGIER, P.; HAMEL, O. Spatial and temporal variations of soil respiration in a Eucalyptus plantation in Congo. **Forest Ecology and Management**, Amsterdam, v. 202, n. 1-3, p. 149-160, 2004.

EPRON, D.; BOSC, A.; BONAL, D.; FREYCON, V. (2006). Spatial variation of soil respiration across a topographic gradient in a tropical rain forest in French Guiana. **Journal of Tropical Ecology**, New York, v. 22, p. 565- 574. Disponível em: <<http://dx.doi.org/10.1017/S0266467406003415>>. Acesso em: 12 mar. 2016.

FERREIRA, D. F. **Estatística multivariada**. Lavras: Ed. UFLA, 2008. 662 p.

FIGUEIREDO, E. B.; LA SCALA JÚNIOR, N. Greenhouse gas balance due to the conversion of sugarcane areas from burned to green harvest in Brazil. **Agricultural, Ecosystems and Environment**, Amsterdam, v. 141, p. 77-85, 2011.

GARCIA, J. C. C.; SPERLING, E. V. Evaluation of greenhouse gas emission by ethanol production from sugarcane (case study of Minas Gerais, Brazil). In: WORLD RENEWABLE ENERGY CONGRESS - WREC, 2011, Linkoping. **World Renewable Energy Congress – Sweden**: [S.n.], 2011.

HAYKIN, S. **Neural networks: a comprehensive foundation**. Upper Saddle River: Prentice-Hall, 1999.

HECHT-NIELSEN, R. **A basic introduction to neural networks**. Madison: Computer Sciences Department at the University of Wisconsin, 1996.

IPCC. Climate change 1995. **The science of climate change**. In: HOUGHTON, J. T ; MEIRA FILHO, L. G.; CALLANDER, B. A.; HARRIS, N.; KATTEMBERG, K.; MASKELL, K. (Ed.). Cambridge: University Press, 1996.

IPCC - Intergovernmental panel on climate change. **Climate change 2007: the physical science basis**. Summary for policymakers, Geneva, Suíça. Disponível em: <[http://www.ipcc.ch/publications\\_and\\_data/publications\\_ipcc\\_fourth\\_assessment\\_report\\_wg1\\_report\\_the\\_physical\\_science\\_basis.htm](http://www.ipcc.ch/publications_and_data/publications_ipcc_fourth_assessment_report_wg1_report_the_physical_science_basis.htm)>. Acesso em: 12 mar. 2016.

IPCC (Painel Intergovernamental de Mudanças Climáticas)/2014. **Relatório de mudanças climáticas**. Disponível em: <[http://www.ipcc.ch/pdf/assessment-report/ar5/syr/AR5\\_SYR\\_FINAL\\_SPM.pdf](http://www.ipcc.ch/pdf/assessment-report/ar5/syr/AR5_SYR_FINAL_SPM.pdf)>. Acesso em: 12 abr. 2016.

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

KIEHL, J. T.; TRENBERTH, K. E. Earth's Annual Global Mean Energy Budget. **Bulletin of the American Meteorological Society**, Boston, v. 78, p. 197-208, 1997.

KOVACS, Z. L. **Redes neurais artificiais fundamentos e aplicações**. São Paulo: Ed. Da USP., 1996. 174 p.

KROSE, B.; SMAGT, P. V. **An introduction to neural networks**. Amsterdam: University of Amsterdam, 1996.

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

LAMOTHE, A. **Neural netware**. [S.l.:S.n.], January 1998.

LENTZSCH, P.; WIELAND, R.; WIRTH, S. Application of multiple regression and neural network approaches for landscape-scale assessment of soil microbial biomass. **Soil Biology & Biochemistry**, Oxford, v. 37, p. 1577–1580, 2005.

LIMA, C. M.; LABIDI, S. **Introdução à inteligência artificial**. São Luiz: FAPEMA, 1999.  
LIU, H. On the Levenberg-Marquardt training method for feedforward neural networks. In PROCEEDINGS OF THE 2010 INTERNATIONAL CONFERENCE ON NATURAL COMPUTATION, ICNC'10, volume 1. 2010.

LUCA, E. F.; FELLER, C.; CERRI, C. C.; BARTHÈS, B.; CHAPLOT, V.; CAMPOS, D. C.; MANECHINI, C. Avaliação de atributos físicos e estoques de carbono e nitrogênio em solos com queima e sem queima de canavial. **Revista Brasileira de Ciência do Solo**, Viçosa, 32, n. 2, p. 789-800, 2008.

MASTERS, T. **Advanced algorithms for neural networks: A C++ Sourcebook/Book**. New York: John Wiley & Sons, 1995.

McCULLOCH, W. W.; PITTS, W. A. Logical calculus of the ideas imminent in nervousactivity. **Bulletin of Mathematical Biophysics**, New York, v. 5, n. 2, p. 114-133, 1943.

MEHDAWI, A. A.; BIN AHMAD, B. Classification of forest change by integration of remote sensing data with neural network techniques.. In: INTERNATIONAL CONFERENCE ON SYSTEM ENGINEERING AND TECHNOLOGY (ICSET), 2012, Bandung. **Proceedings of the...** Bandung: IEEE, 2012. p. 1-5, 11-12.

MENDES FILHO, E. F.; CARVALHO, A. C. P. L. **Tutorial introdutório sobre redes neurais artificiais**. São Paulo: Departamento de Ciências de Computação e Estatística - USP, 1997.

MINGOTI, S. A. **Análise de dados através de métodos de estatística multivariada: uma abordagem aplicada.** Belo Horizonte: UFMG, 2005. 295 p.

MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO. **Relatório:** estimativas anuais de emissões de gases de efeito estufa no Brasil. Brasília, DF: MCTE, 2014.

MOITINHO, M. R.; PADOVAN, M. P.; PANOSSO, A. R.; LA SCALA, N. Efeito do preparo do solo e resíduo da colheita de cana-de-açúcar sobre a emissão de CO<sub>2</sub>. **Revista Brasileira de Ciência do Solo**, Viçosa, v.37, p.1720-1728, 2013. Disponível em: <<http://www.scielo.br/pdf/rbcs/v37n6/28.pdf>>. Acesso em: 12 jan. 2016.

MOLION, L. C. B. Aquecimento lobal: uma visão crítica. **Revista Brasileira de Climatologia**, Presidente Prudente, v.3/4, p. 7-24, 2008.

NUNES, C.; MARTINHO, V. R. C.; MINUSSI, C. R. A New method for the prediction of carbon sequestration in reforested areas using a fuzzy-art-bp neural network. In: INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE 2013 - ICAI'13, 2013, Las Vegas. **Proceedings of the...** Las Vegas: IEEE, 2013. v. 1. p. 825-831.

OECD - **Estimation of greenhouse gas emissions and sinks.** OECD Expert Meeting, Background Report, 1991.

PANOSSO, A. R.; MARQUES, J.; MILORI, D.; 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**, Amsterdam, v. 111, p. 190-196, 2011.

PANOSSO, A. R.; PEILLO L. I.; FERRAUDO A. S.; PEREIRA, G. T.; MIRANDA J. G. V.; LA SCALA Jr., N. Fractal dimension and anisotropy of soil CO<sub>2</sub> emission in a mechanically harvested sugarcane production área. **Soil & Tillage Research**, Amsterdam, v. 124, p. 8–16, 2012.

RAIJ, B. van; ANDRADE, J. C.; CANTARELA, H. ; QUAGGIO, J. A. **Análise química para avaliação de solos tropicais.** Campinas, Instituto Agronômico de Campinas, 2001. 285 p.

RAYMENT, M. B.; JARVIS, P. G. Temporal and spatial variation of soil CO<sub>2</sub> efflux in a Canadian boreal forest. **Soil Biology and Biochemistry**, Oxford, v. 32, n. 1, p. 35-45, 2000.

RAZAFIMBELO, T.; BARTHÈS, B.; LARRÉ-LARROUY, M. C.; DE LUCA, E. F.; LAURENTE, J. Y.; CERRI, C. C.; FELLER, C. Effect of sugarcane residue management (mulching versus burning) on organic matter in a clayey Oxisol from southern Brazil. **Agriculture Ecosystem & Environment**, Kathmandu, v. 115, p. 285-289, 2006.

SANTOS, H. G.; JACOMINE, P. K. T.; ANJOS, L. H. C.; OLIVEIRA, V. A.; OLIVEIRA, J. B.; COELHO, M. R.; LUMBRERA, J. F.; CUNHA, T. J. F. **Sistema brasileiro de classificação de solos.** Rio de Janeiro: Embrapa Solos, 2013.

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**, Philadelphia, v. 25, n. 5, p. 441-472, 2006.

SCHULTZ, A.; WIELAND, R. LUTZE, G. Neural networks in agroecological modelling—stylish application or helpful tool ?. **Computers and Electronics in Agriculture**, Amsterdam, v. 29, p. 73-97, 2000.

SOARES, C. P. B.; LEITE, H. G.; GORGENS, E. B. Equações para estimar o estoque do carbono no fuste de árvores individuais e em plantios comerciais de eucalipto. **Revista Árvore**, Viçosa, v. 29, n. 5, p. 711-718, 2005.

SOBREIRO, V. A.; ARAÚJO, P. H. S. L.; NAGANO, M. S. Precificação do etanol utilizando técnicas de redes neurais artificiais. **Revista Administração**, São Paulo, v. 44, n. 1, p. 46-58, 2009.

SONG, X.; PENG, C.; ZHAO, Z. S.; ZHANG, Z.; GUO, B.; WANG, W.; JIANG, H.; ZHU, Q. Quantification of soil respiration in forest ecosystems across China. **Atmospheric Environment**, Oxford, v. 94, p. 546-551, 2014.

SPECHT, D. F. Probabilist Neural Networks for Classification, Mapping or Associative Memory. Proc. **IEEE International Conference on Neural Networks**, New York, v. 1, p. 525-532, 1988.

SPECHT, D. F. A generalized regression neural network. **IEEE Transactions on Neural Networks**, New York, v. 2, p. 568-576, 1991.

TEIXEIRA, D. D. B.; BICALHO, E. S.; PANOSSO, A. R.; PERILLO, L. I.; IAMAGUTI, J. L.; PEREIRA, G. T.; LA SCALA, N. Uncertainties in the prediction of spatial variability of soil CO<sub>2</sub> emissions and related properties. **Revista Brasileira de Ciência do Solo**, Viçosa, v. 36, p. 1466-1475, 2012. Disponível em: <<http://dx.doi.org/10.1590/S0100-6832012000500010>>. Acesso em: 15 jan. 2016.

UNICA – **União da indústria de cana-de-açúcar**. Disponível em: <<http://www.unicadata.com.br>>. Acesso em: 23 jun. 2016.

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**, Amsterdam, v. 104, n. 1, p. 39-47, 2009.

VIEIRA, S.R. Geoestatística aplicada à agricultura de precisão. In: BOREM, A.; GIUDICE, M. P.; QUEIROZ, D. M.; MANTOVANI, E. C.; FERREIRA, L. R.; VALLE, F. X. R.; GOMIDE, R. L. **Agricultura de Precisão**. Viçosa: Ed. UFV, 2000. p. 93-108.

WANG, G.; GERTNER, G.; SINGH, V.; SHINKAREVA, S.; PARYSOW, P.; ANDERSON, A. Spatial and temporal prediction and uncertainty of soil loss using the revised universal soil loss equation: a case study of the rainfall-runoff erosivity R factor. **Ecological Modelling**, Amsterdam, v.153, p.143-155, 2002.

WASSERMAN, P. D. **Neural computing: theory and practice.** New York: Van Nostrand Reinhold, 1989.

WEBSTER, R.; OLIVER, M. A. **Statistical methods in soil and land resource survey.** New York: Oxford University Press, 1990. 328 p.

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**, Winston, v. 78, n. 9, p. 1415-1442, 1990