

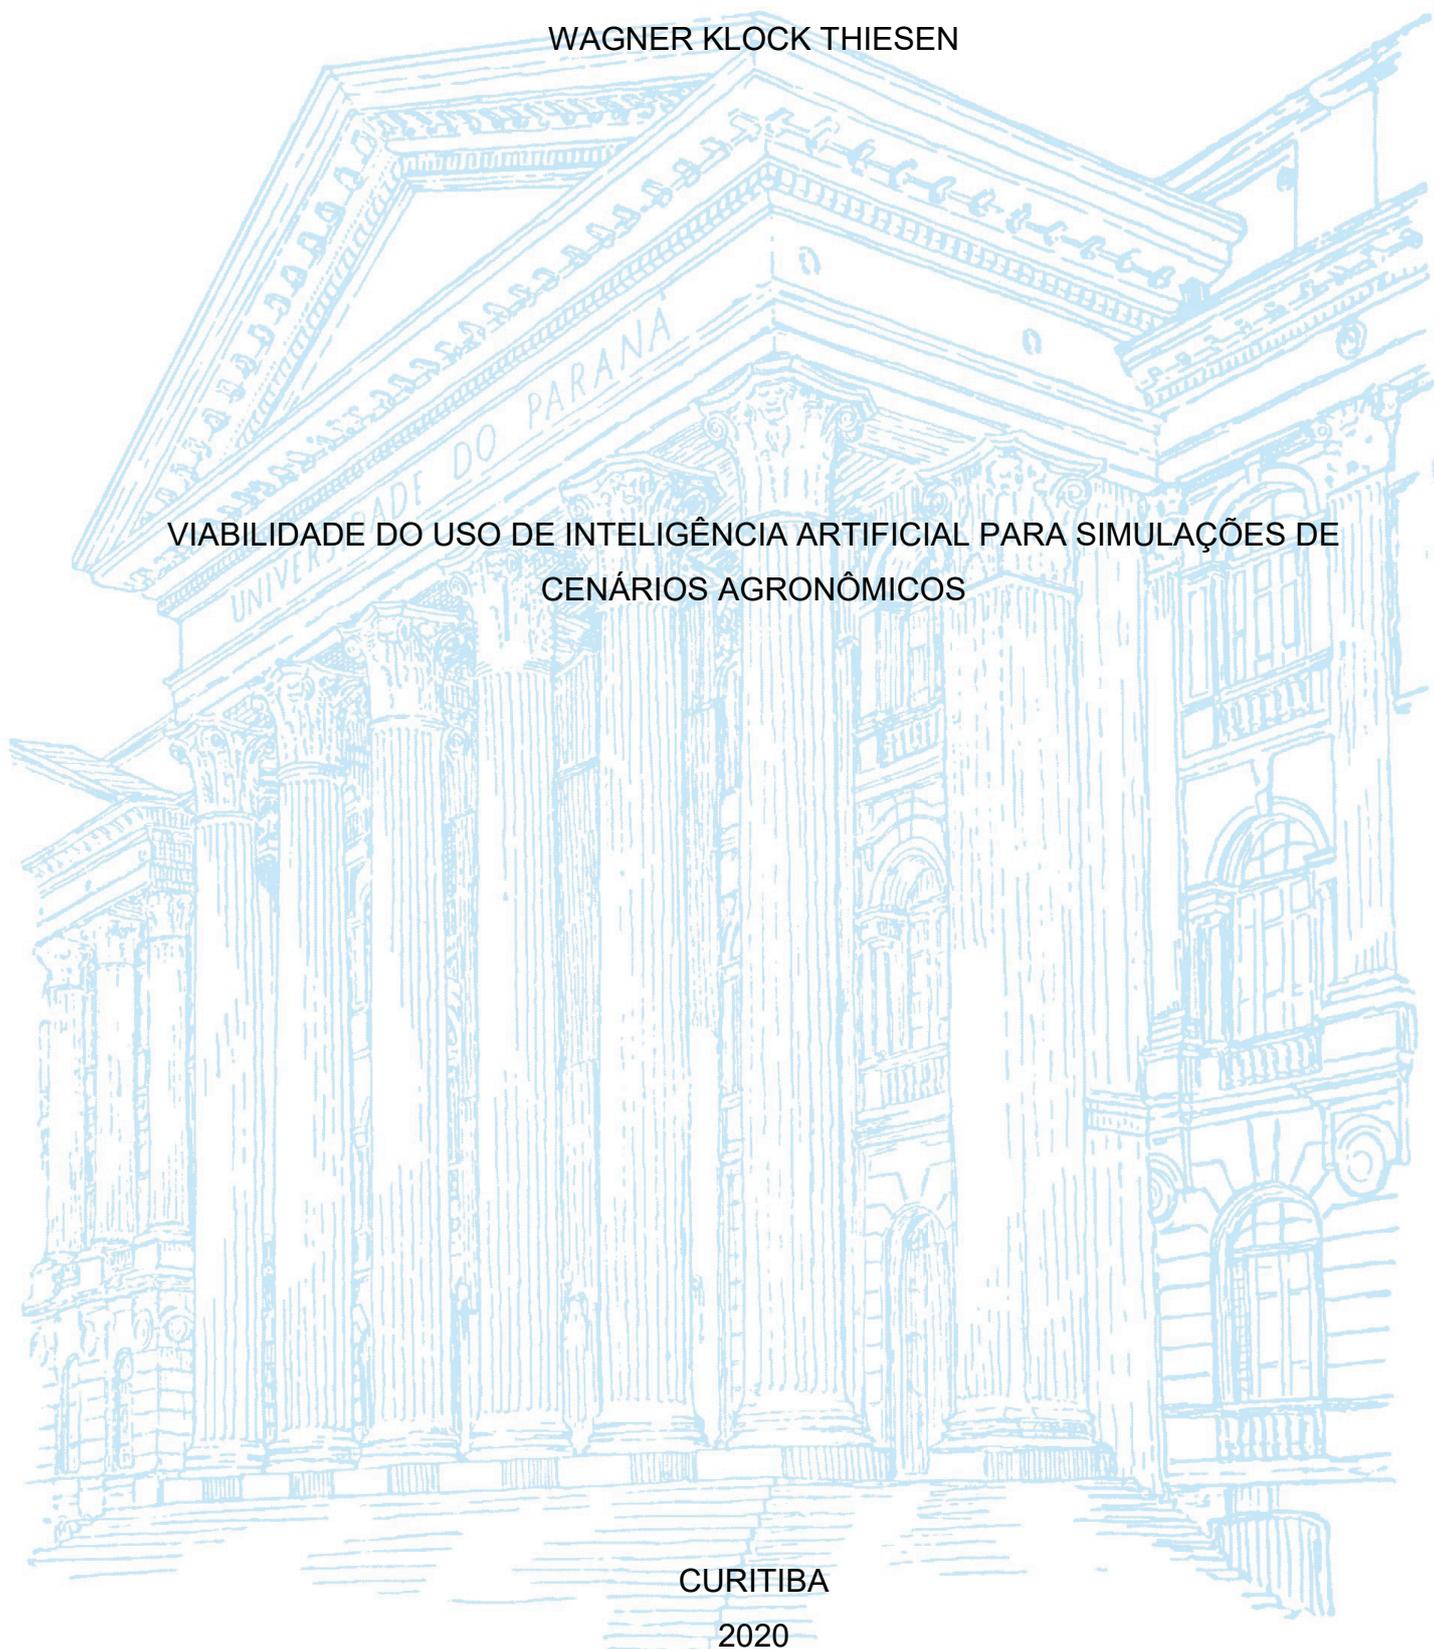
UNIVERSIDADE FEDERAL DO PARANÁ

WAGNER KLOCK THIESEN

VIABILIDADE DO USO DE INTELIGÊNCIA ARTIFICIAL PARA SIMULAÇÕES DE
CENÁRIOS AGRONÔMICOS

CURITIBA

2020



WAGNER KLOCK THIESEN

VIABILIDADE DO USO DE INTELIGÊNCIA ARTIFICIAL PARA SIMULAÇÕES DE
CENÁRIOS AGRONÔMICOS

Monografia apresentada ao curso de Pós-Graduação em Fertilidade do Solo e Nutrição de Plantas, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Especialista em Fertilidade do Solo e Nutrição de Plantas.

Orientador: Prof. Ms. Ederlan Magri

Coorientador: Prof. Dr. Eloá Moura Araujo

CURITIBA

2020

TERMO DE APROVAÇÃO

WAGNER KLOCK THIESEN

VIABILIDADE DO USO DE INTELIGÊNCIA ARTIFICIAL PARA SIMULAÇÕES DE CENÁRIOS AGRONÔMICOS

Monografia apresentada ao curso de Pós-Graduação em Fertilidade do Solo e Nutrição de Plantas, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Especialista em Fertilidade do Solo e Nutrição de Plantas.

Prof. Msc. Ederlan Magri

Orientador(a) – Setor de Ciências Agrárias, UFPR

Profa. Dra. Eloá Moura Araujo

Setor de Ciências Agrárias, UFS

Prof. Msc. Valdécio dos Santos Rodrigues

Setor de Ciências Agrárias, UFPR

Cidade, 20 de agosto de 2020.

Dedico esse trabalho a todos que me apoiaram para a conclusão dessa fase de minha vida, em especial para minha esposa Ana Carolina e minhas filhas Julia e Giovana.

O sucesso é a soma de pequenos esforços - repetidos dia sim, e no outro
dia também.

ROBERT COLLIER

RESUMO

Diante da crescente demanda de alimentos sem explorar novas áreas de plantio, faz-se necessária a otimização da cadeia agrícola, seja financeira ou por meio de acréscimo de produtividade. Para tanto, este trabalho apresenta um estudo sobre a viabilidade do uso de inteligência artificial para simulações de cenários agrônômicos utilizando-se do método de redes neurais artificiais (RNA). O estudo compreendeu a pesquisa dos fatores que influenciam o crescimento e desenvolvimento de plantas, dentre esses são apresentados os fatores relacionados ao clima, ao solo e as plantas. Também foi realizada pesquisa complementar objetivando localizar coeficientes que poderiam ser utilizados para desenvolvimento dos modelos de RNA, no entanto, não foram localizados resultados no acervo de pesquisa. Dessa forma, ainda não estão disponíveis dados históricos comparáveis e suficientes para desenvolvimento do modelo de RNA. Concluiu-se também que não é possível possuir apenas um modelo de RNA que se aplique a todo o contexto agrônômico em função das necessidades relacionadas a cada espécie da planta, ao sistema de cultivo e as características climáticas locais. Apesar do contexto apresentado, a utilização de RNA para a simulação de cenários agrônômicos é possível e viável.

Palavras-chave: planta; fatores de crescimento e desenvolvimento; redes neurais artificiais.

ABSTRACT

In view of the growing demand for food without exploring new planting areas, it is necessary to optimize the agricultural chain, be it financial or through increased productivity. For that, this work presents a study on the feasibility of using artificial intelligence to simulate agronomic scenarios using the method of artificial neural networks (ANN). The study comprised the research of the factors that influence the growth and development of plants, among which are presented the factors related to climate, soil and plants. Complementary research was also carried out in order to locate coefficients that could be used for the development of ANN models, however, no results were found in the research collection. Thus, comparable and sufficient historical data for the development of the ANN model are not yet available. It was also concluded that it is not possible to have only one ANN model that applies to the entire agronomic context, depending on the needs related to each species of the plant, cultivation system and local climate conditions. Despite the context presented, the use of RNA for the simulation of agronomic scenarios is possible and feasible.

Keywords: plant; growth and development factors; Artificial neural networks.

LISTA DE FIGURAS

FIGURA 1 – Fatores de influência.....	17
FIGURA 2 – Influência da taxa de crescimento de milho para doze cultivares	19
FIGURA 3 – Velocidade de fotossíntese e comprimento de onda	20
FIGURA 4 - Quantidade de horas com incidência de luz em um dia em diferentes latitudes.....	21
FIGURA 5 – Resposta da fotossíntese ao incremento de irradiação	22
FIGURA 6 – Ponto de compensação fótico.....	23
FIGURA 7 – Resposta da fotossíntese ao incremento de luminosidade para diferentes espécies	24
FIGURA 8 - Água encontrada comumente em diferentes plantas e suas partes	25
FIGURA 9 – Disponibilidade dos nutrientes em função do pH.....	33
FIGURA 10 – Classificações das tarefas, à esquerda, descrição e a direita a representação é da predição.....	36
FIGURA 11 – Modelo de neurônio biológico simplificado	39
FIGURA 12 – Modelo de neurônio artificial	40
FIGURA 13 – Redes neurais com duas e quatro camadas.....	41

LISTA DE TABELAS

TABELA 1 - Estágios críticos ao estresse hídrico para diversas espécies.....	26
TABELA 2 – Funções e sintomas de deficiência dos macronutrientes	29
TABELA 3 – Funções e sintomas em caso de deficiência, nas plantas, dos micronutrientes.....	30
TABELA 4 - Faixa ótima de pH para algumas culturas	32

LISTA DE ABREVIATURAS OU SIGLAS

Al – Alumínio

AM – Aprendizado de máquina

B – Boro

Ca – Cálcio

Cl – Cloro

CO₂ – Dióxido de carbono

Cu – Cobre

Fe – Ferro

K – Potássio

Mg – Magnésio

Mn - Manganês

Mo - Molibdênio

N – Nitrogênio

P – Fósforo

PTH – Poder tampão hidrogeniônico

RNA – Rede Neural Artificial

S – Enxofre

Zn – Zinco

LISTA DE SÍMBOLOS

Σ - somatório de números

SUMÁRIO

1 INTRODUÇÃO	12
1.1 JUSTIFICATIVA	13
1.2 OBJETIVOS	13
1.2.1 Objetivo geral	13
1.2.2 Objetivos específicos.....	13
1.3 METODOLOGIA.....	14
2 REVISÃO DE LITERATURA	15
2.1 FATORES DE INFLUÊNCIA	16
2.1.1 Clima	Erro! Indicador não definido.
2.1.2 Temperatura.....	18
2.1.3 Luminosidade	20
2.1.4 Pluviosidade	24
2.1.5 Ventos	27
2.1.6 Solo	27
2.2 INTELIGÊNCIA ARTIFICIAL	33
2.2.1 Aprendizagem de Máquina.....	35
2.2.2 Conjunto de dados	37
2.2.3 Redes Neurais Artificiais	38
3 RESULTADO E DISCUSSÃO	43
4 CONSIDERAÇÕES FINAIS	45
REFERÊNCIAS.....	46

1 INTRODUÇÃO

Muitos estudos vêm sendo realizados com projeções alarmantes quanto a necessidade crescente de alimentos para abastecimento da população mundial. Este assunto nos depara com a limitação de espaço de cultivo para a produção de alimentos e também ao elevado uso de fertilizantes e condicionadores de solo, que possuem reservas limitadas na natureza e aumentam o custo de produção.

Os entraves levantados nos sugerem que para solucionar tal problema, ao menos temporariamente, é necessário recorrer à produção com maior eficiência, produzindo mais com o mesmo ou uma menor quantidade de insumos e espaço. As ferramentas que possuímos atualmente já não bastam para esta solução, mas podem nos auxiliar na construção de novas soluções. Isso já foi observado por outros autores conforme pode ser verificado abaixo:

“Nas últimas décadas, com a crescente complexidade dos problemas a serem tratados computacionalmente e do volume de dados gerados por diferentes setores, tornou-se clara a necessidade de ferramentas computacionais mais sofisticadas, que fossem mais autônomas, reduzindo a necessidade de intervenção humana e dependência de especialistas. Para isso, essas técnicas deveriam ser capazes de criar por si próprias, a partir da experiência passada, uma hipótese, ou função, capaz de resolver o problema que se deseja tratar” (FACELI, 2011, p.2).

A diversidade de soluções que poderiam ser utilizadas para solucionar esses problemas apresentados é vasta. Na prática, verificamos a criação de equipamentos de maior eficiência de aplicação dos nutrientes, desenvolvimento de cultivares com capacidade para o melhor aproveitamento das condições climáticas e do solo. A proposta que se faz é a utilização de tecnologia para superar a limitação física do ser humano de predizer funções, para tanto se valendo da enorme quantidade de dados é gerada.

Em termos amplos, estima-se que a cada 20 meses é dobrada a quantidade de dados armazenada nos bancos de dados do mundo. Essa enorme quantidade de dados, não pode ser processada por uma questão de limitação física pelo ser humano. Contudo, já existem métodos por meio do processamento computacional que possibilitam a união das características a partir de dados existentes, que possibilite a predição de determinados efeitos. Tais predições são possíveis no ambiente da inteligência artificial, especialmente falando de redes neurais artificiais.

1.1 JUSTIFICATIVA

Atualmente possuímos alguns métodos de interpretação de análise química do solo que são limitados aos extratores, sendo que o mais eficiente tenta simular o que a planta extrai. No entanto, da mesma forma, este e os demais métodos existentes não se preocupam em considerar outros fatores envolvidos no processo de crescimento da planta como luminosidade e pluviosidade. O método proposto nesse trabalho vai além da interpretação da análise química do solo, propondo a construção de modelo matemático por inteligência artificial utilizando redes neurais.

Justifica-se a importância desse estudo na possibilidade de entender o sistema planta-solo-clima como um só e que se aperfeiçoe de forma continuada, acompanhando as mudanças climáticas, desenvolvimento de novos espécimes e possibilitando a simulação de cenários. Para possibilitar as simulações propostas haverá entrada de dados dos fatores influenciadores e como resultado haverá saída de estimativa de produtividade. Com essas simulações, os técnicos e produtores rurais poderão tomar uma decisão assertiva sobre os quantitativos de adubação e de agrotóxicos a serem aplicados na propriedade, visto que antecipadamente à consecução do ciclo agrônomo, poderão visualizar a produtividade. Percebe-se então que o resultado que será alcançado com a utilização do modelo proposto é a otimização da cadeia financeira agrícola.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Realizar o levantamento dos fatores que influenciam o crescimento e desenvolvimento das plantas com foco na produtividade e verificar se pode ser modelado para o uso de inteligência artificial com o método de redes neurais.

1.2.2 Objetivos específicos

a. Quais são os fatores que influenciam o crescimento e desenvolvimento das plantas?

b. Já foram determinados ou estimados basicamente os coeficientes que representem os fatores apresentados no item “a”?

c. É possível a utilização de redes neurais para determinação de cenários agrônômicos com o que possuímos de bibliografia atualmente?

1.3 METODOLOGIA

Foi utilizado o método de revisão bibliográfica narrativa a fim de localizar os principais fatores de influência na produção de plantas, bem como os conceitos relacionados a esses fatores.

As buscas foram realizadas na “Biblioteca Virtual” (bvirtual.com.br) e “Biblioteca Virtual” mantida pela Universidade Banco do Brasil (unibb.com.br), além de pesquisa nos repositórios “SciELO” e “ScienDirect”, e em livros.

Os termos buscados foram “fatores de influência em desenvolvimento de plantas”, “desenvolvimento de plantas”, “fisiologia de plantas”, “inteligência artificial”, “rede neural”, “aprendizado de máquina”, “regressão não-linear”, bem como suas traduções em inglês. Não houve restrição do ano de publicação dos trabalhos buscados.

Apesar de não ter sido tratada da aplicação formal do método de inteligência artificial estudado, houve pesquisa com o intuito de compreender e reunir elementos para futura implementação do método conhecido como redes neurais.

O trabalho não tem o intuito de esgotar o assunto ou mesmo as fontes de pesquisa disponíveis em busca de informações que auxiliem ou apresentem a solução do problema, mas sim possibilitar o início do estudo e desenvolvimento da ideia.

2 REVISÃO DE LITERATURA

A agricultura tem como principal objetivo a produção de alimentos para a população mundial. No entanto, para possibilitar a consecução desse objetivo, é necessária a viabilidade econômica dessa atividade. Assim, a atividade deixa de possuir somente o cunho agrônomo e social e passa também a ser vista em termos de finanças e economia. A margem econômica disponível na atividade varia entre as culturas e também de acordo com a localização da propriedade, tipo de solo etc.

Para exemplificar, foi calculada a margem líquida para soja para o entorno de Cascavel (PR), que é de aproximadamente 5%, ou seja, o preço de venda descontado o custo de produção, as depreciações, os seguros e disponibilidade de risco resulta nesse percentual de retorno da atividade. A fim de possibilitar a comparação, tomou-se por base a representatividade de aplicações financeiras disponíveis em diversas instituições financeiras do mercado, essas que remuneram até 90% da taxa básica de juros da economia brasileira, que na atualidade é de 5% ao ano, importante considerar que são produtos com classificações de risco muito baixo a baixo e sem incidência de imposto de renda, para pessoas físicas. Assim se vislumbra a importância de possibilitarmos uma contínua melhoria no estudo da otimização da produtividade de plantas.

O estudo da otimização da produtividade de plantas sob a ótica financeira tem como fundamento a utilização de um mesmo investimento financeiro com incremento de retorno em decorrência de um aumento de produtividade. Esse aumento pode ser conseguido através da redução da aplicação de determinado nutriente e aplicação doutro, utilização de tecnologia superior de manejo, estudo da influência climática com alteração de data de plantio dentre outras.

O que ocorre é que possuímos no mundo uma grande variedade de espécies de plantas, algumas ainda nem catalogadas ou estudadas de forma apropriada. Esses organismos possuem uma infinidade de características de crescimento, podendo variar temporalmente. Por exemplo, em sua caracterização de ciclos, podendo ser anuais, bianuais dentre outros; na quantidade e distribuição durante o seu ciclo de água que necessitam; e luminosidade. Dessa forma, para cada grupo de plantas existem características específicas que possibilitam o seu crescimento, podendo variar desde o ambiente no qual estão localizadas as

sementes até a temperatura da região durante o crescimento da planta como nos ensina AVRDC (1990).

“Elas se diferem nos requisitos de crescimento. Muitos vegetais podem crescer em uma grande faixa de condições; enquanto outros possuem requisitos mais específicos para água, temperatura e luz. Assim em um local, várias espécies crescem durante o ano todo, mas algumas outras somente podem crescer durante algumas épocas do ano. A irrigação é uma necessidade absoluta para muitas espécies, enquanto outras podem crescer em condições de escassez de chuva.” (AVRDC, 1990, p.1).

2.1 FATORES DE INFLUÊNCIA

Segundo PESSARAKLI (2001), deve existir um equilíbrio no ambiente que a planta se apresenta para crescimento. De forma contrária se faltante ou em excesso algum dos termos, a planta poderá vir a ter comportamento de stress ou mesmo morrer. Também cita os vários fatores que afetam o crescimento e o desenvolvimento de plantas, tomaremos como os principais, de forma arbitrária, os descritos a seguir:

- a) Clima;
- b) Temperatura;
- c) Luminosidade;
- d) Pluviosidade;
- e) Ventos;
- f) Solo.

Já para NOVAIS (2007), há o acréscimo de fatores que são relacionados à planta e também da altitude/latitude como é possível visualizar na figura FIGURA 1 – Fatores de influência.

FIGURA 1 – Fatores de influência

<i>Fatores climáticos</i>	<i>Fatores de solo</i>	<i>Fatores de Planta</i>
Precipitação pluvial - quantidade - distribuição	Material de origem Estrutura Textura	Espécies, cultivares Fatores genéticos Qualidade da semente
Temperatura do ar	Profundidade	Nutrição
Umidade relativa	Declividade e topografia	Eficiência da absorção
Luz - quantidade - intensidade - duração	Temperatura Reação (pH) Matéria orgânica	Disponibilidade de água Evapotranspiração Moléstias
Altitude/latitude	Atividade de microrganismos Capacidade de troca de cátions	- insetos - bactérias - fungos - vírus
Ventos - velocidade - distribuição	Saturação por bases Sistema de plantio Sistema de manejo	Plantas invasoras

FONTE: NOVAIS (2007)

2.1.1 Condições Climáticas e Paisagem

Segundo AVRDC (1990), podemos conceituar o tempo como uma dada condição que ocorre em uma determinada localidade, sendo que essa condição pode ser descrita em alguns termos, sendo temperatura, pluviosidade, duração e intensidade de luz, velocidade e direção dos ventos e umidade relativa. Ainda nos ensina que o tempo se altera todo dia, enquanto que o clima é o padrão de repetição do tempo em determinada localidade.

Importante ressaltar que possuímos algumas mudanças drásticas em termos de clima em função da distância da superfície do solo, isso pode ser exemplificado pela temperatura que muito próximo ao solo é muito superior a temperatura a alguns centímetros acima.

Alguns dos termos que foram apresentados podem ser alterados artificialmente e moldados para apresentar um resultado mais favorável ao desenvolvimento de determinados espécimes. Por exemplo, quanto a pluviosidade

pode-se implantar um sistema de irrigação, no entanto, fazendo-se isso, também haverá alterações de temperatura e umidade relativa. Dessa forma, é necessário estudar efetivamente qual é o impacto de uma alteração apresentada como simples nesse fator pois, normalmente se transformará em de consequência complexa.

Podemos elencar ainda junto aos termos de tempo e clima, a topografia, que se refere à elevação e rugosidade macroambiental da superfície terrestre. Esse é um fator fundamental, uma vez que em vales existe um comportamento diferenciado de planícies e assim por diante o que modifica a análise como fator do tempo e clima.

Percebe-se então que para a utilização desse fator, tanto para aprendizado como para predição, no desenvolvimento do método em estudo é necessário que exista uma homogeneidade em relação aos termos que o compõe, especialmente no que se refere à topografia, temperatura e distribuição de pluviosidade.

2.1.1.1 Temperatura

AVRDC (1990) dita que a temperatura usualmente é considerada como o termo mais importante na escolha do local de planta quando têm-se como objetivo a colheita, ou seja, produção. Explica ainda que a temperatura, influencia todas as atividades fisiológicas por meio de controle da taxa de reações químicas com impactos em florescimento, viabilização de polinização, balanço hormonal, taxa de maturação e senescência e qualidade do produto gerado. Além das consequências que a temperatura exerce no crescimento, também afeta o tempo de colheita, pois ela está relacionada com a velocidade de maturação da planta.

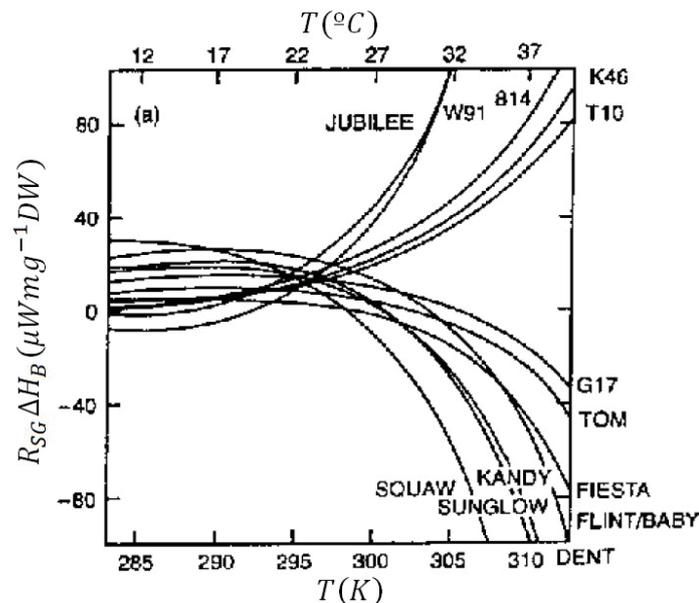
É perceptível a faixa estreita de sobrevivência que as plantas possuem na observação feita por AVRDC (1990): “À 0°C as plantas são mortas pelo frio, e à 40°C elas são mortas pelo calor”, acrescenta ainda que “muitas plantas sofrem danos permanentes à 10°C ou mesmo em 15°C, e a maioria deixa de realizar fotossíntese de forma eficiente acima dos 30°C”. Já para NOVAIS (2007) a faixa de crescimento das espécies situa-se em média entre 15 e 40°C, complementa ainda que em temperaturas muito baixas ou muito acima destas, o crescimento das plantas é rapidamente limitado.

Ainda segundo AVRDC (1990), para os trópicos, pode se considerar que a temperatura possui um decréscimo de 0,6°C para cada 91,50m de aumento de

elevação – acima do nível do mar. Isso possibilita entender a estreita ligação que a temperatura possui com a topografia.

Também foi ilustrado por PESSARAKLI (2001), que para uma mesma espécie, existe grande variação do efeito da temperatura em diferentes cultivares (figura FIGURA 2).

FIGURA 2 – Influência da taxa de crescimento de milho para doze cultivares



FONTE: PESSARAKLI (2001)

Acrescenta ao termo gráfico mostrado mais algumas informações, concluídas a partir da figura: “Os diferentes cultivares de milho (*Zea mays* L.) são cultivadas no mundo todo. Assim as taxas de crescimento de alguns desses cultivares aumentem em baixas temperaturas, se elevam ao máximo na faixa de crescimento "normal" enquanto diminuem em temperaturas mais altas.” (PESSARAKLI, 2001).

Até o momento elencou-se a influência da temperatura como um todo, no entanto, cabe ressaltar que a temperatura do solo, segundo AVRDC (1990) é o fator maior que determina a taxa de crescimento e desenvolvimento microbiano, decomposição de matéria orgânica, germinação de sementes, desenvolvimento de raízes, além da água e nutrientes absorvidos pelas raízes. Nesse momento também é possível compreender que há um estreitamento com a luminosidade e tempo de exposição do sol:

“The amount of heat absorbed by the soil increases with the intensity and duration of sunshine. Dark-colored soils absorb more solar energy than light-colored ones. The capacity of water to move heat from one area to another (conduction) is greater than

that of air. Heat is therefore released to the surface faster in wet clayey soils than in dry sandy soils. The lower the air temperature, the more rapid the loss. Thus, although light-colored Sandy soils absorb less solar energy, less heat is also released to the atmosphere because of the low water-holding capacity of the soil" (AVRDC, 1990, p. 59).

Dessa forma, faz-se plausível a utilização de um fator que descreva a temperatura média durante o ciclo além de um fator que indique fuga durante o ciclo para situações de estresse. Considerando que existem plantas de ciclo de inverno, será considerada a faixa de sobrevivência indicada por AVRDC (1990).

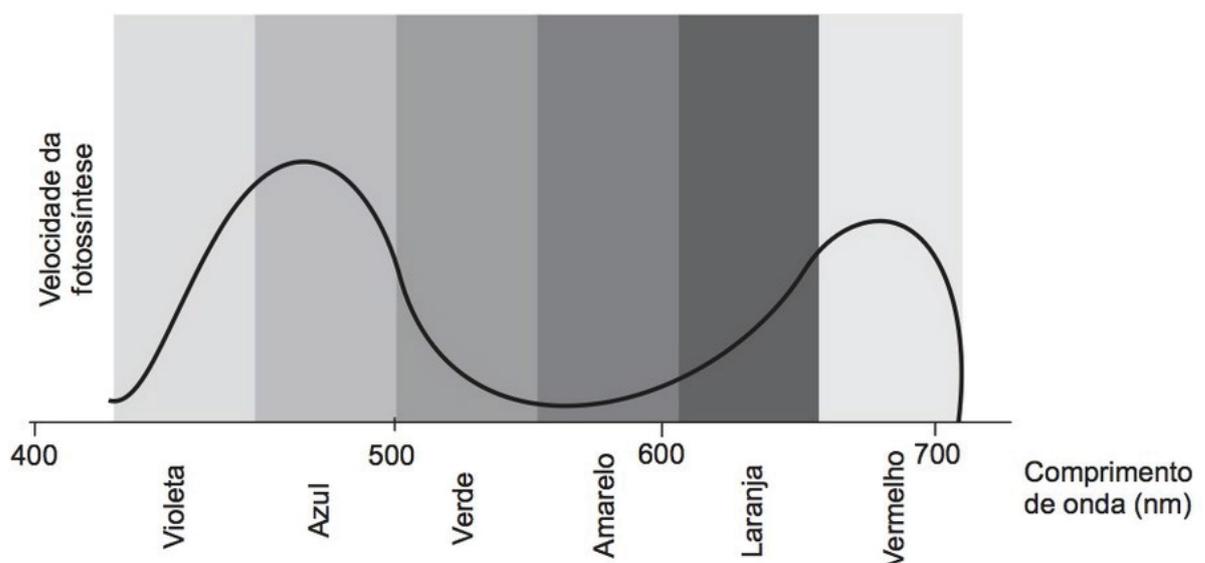
2.1.1.2 Luminosidade

O sol emite ondas luminosas, que possuem diferentes comprimentos de ondas – definidores das cores da luz, essa combinação de comprimentos de ondas nos aparenta a cor branca ao olho nu (AVRDC, 1990).

No processo de fotossíntese das plantas, os comprimentos de ondas utilizados são os mesmos que visíveis a olho nu humano.

Segundo SCHWAMBACH (2014), a clorofila, principal pigmento para a síntese da fotossíntese, absorve mais intensamente as radiações azuis e vermelhas e, em menor intensidade, as radiações verdes e amarelas. Isso afeta a velocidade de fotossíntese, conforme é possível observar na figura FIGURA 3.

FIGURA 3 – Velocidade de fotossíntese e comprimento de onda



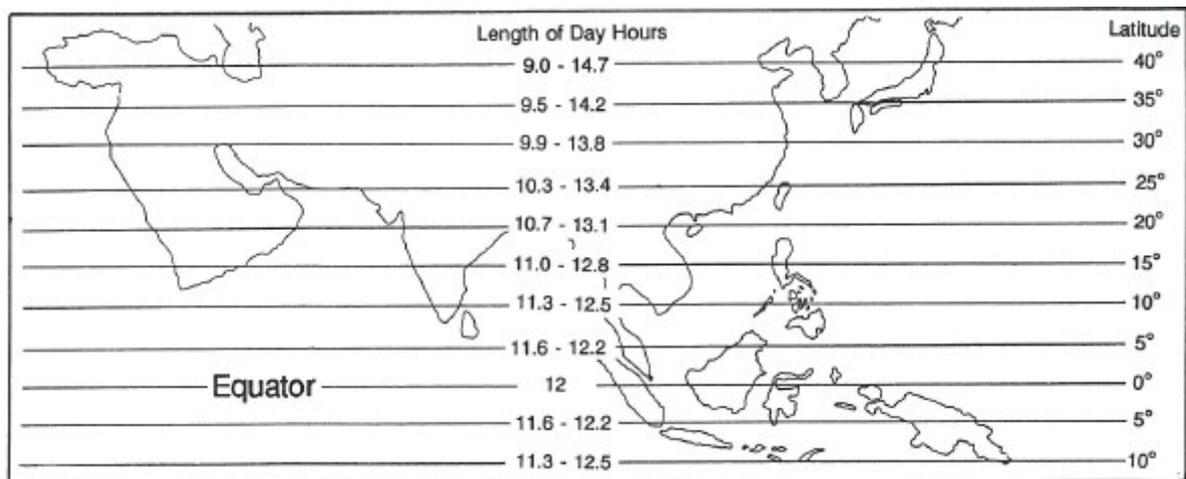
FONTE: SCHWAMBACH (2014)

Quanto ao tempo de duração da luz, AVRDC nos ensina que:

“Since the earth revolves on its axis, tilts at 66° , and travels around the Sun, the length of the light period varies according to the season of the year and latitude. The duration of light, is measured by the number of hours from sunrise to sunset. It is called photoperiod or day length. It varies from a nearly uniform 12-hour Day at the equator (0 latitude) to continuous light or darkness throughout the 24 hours for a part of the year at the poles (...) The farther the area is from the equator, the greater the difference between the shortest and longest day.” (AVRDC, 1990, p. 62).

A variação da quantidade de horas de incidência de luz explicada acima por AVRDC (1990) pode ser visualizado esquematicamente na FIGURA 4 - Quantidade de horas com incidência de luz em um dia em diferentes latitudes.

FIGURA 4 - Quantidade de horas com incidência de luz em um dia em diferentes latitudes



FONTE: AVRDC (1990)

Além disso, MOHAMMAD (2001) indica que a luminosidade é um dos fatores que normalmente se passa despercebido na determinação da temperatura ótima, e nesse caso pode afetar de forma positiva ou negativa a resposta dada a um experimento em dada temperatura.

Dessa forma, também, quando há reporte à disponibilidade de luz às plantas, deve-se realizar um apanhado sobre condições de sombra, para as quais o mesmo autor nos lembra sobre a influência direta na temperatura:

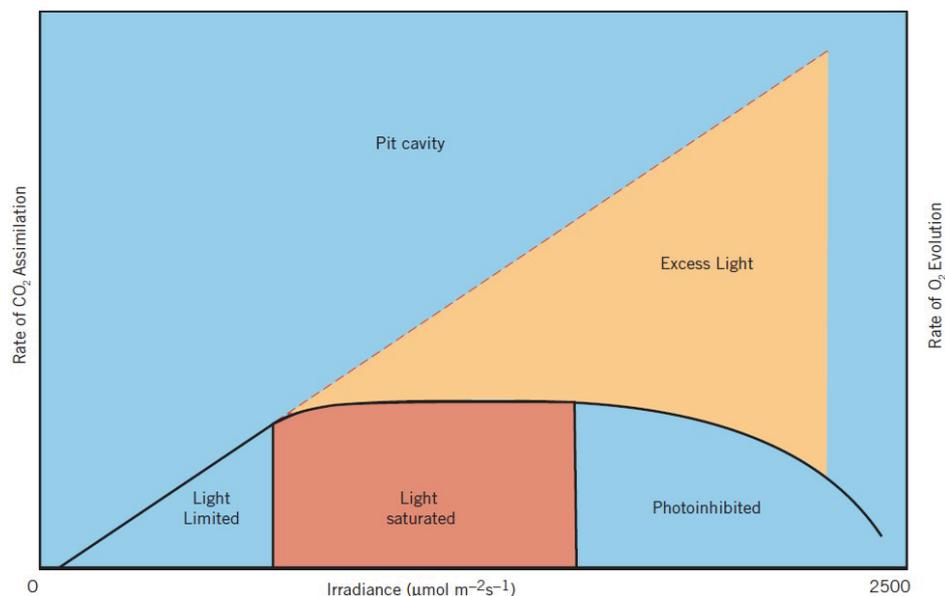
“Shade conditions can be expected not only to lower daytime temperatures but also to raise night temperatures, particularly under cold night–clear sky conditions, in which ground-to-sky radiation can cause a very rapid, possibly harmful, drop in temperature near the ground. Similarly, the use of spectral filters can be expected to modify not only light quality but also temperature.” (MOHAMMAD, 2001, p.24).

Importante destacar que diferentes espécies se comportam de maneira diferenciada para o tempo de exposição à luz. Dessa forma podem ser classificadas como plantas de dias curtos, longos e neutras. É observado que em algumas espécies, quando ultrapassado o fotoperíodo crítico – máximo de exposição adequado – a planta pode suprimir a fase de reprodução.

Além do tempo de exposição, também há influência da intensidade de luz a qual as plantas são expostas, que é diretamente afetado pela estação do ano e elevação em relação ao nível do mar. A título de exemplificação, num dia claro, no topo de uma montanha possuímos uma intensidade de luz 16% superior à mesma condição ao nível do mar.

A exposição a uma adequada intensidade de luz é muito importante, como podemos visualizar na figura a seguir, possuímos o aumento da fotossíntese até a saturação pelo excesso de luz - a esse ponto, chamamos de ponto de saturação luminoso - e logo após, inibição parcial com rápido decréscimo do processo de fotossíntese (FIGURA 5).

FIGURA 5 – Resposta da fotossíntese ao incremento de irradiação



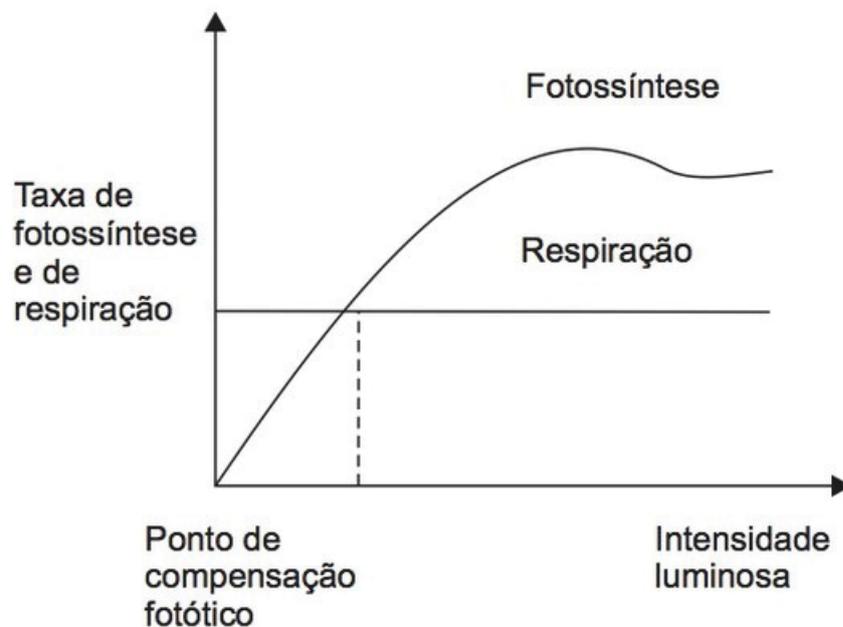
FONTE: HOPKINS (2008)

SCHWAMBACH (2014) mostra que o ponto de compensação luminoso ou ponto fótico é o nome dado à intensidade luminosa em que as taxas de fotossíntese e de respiração se anulam.

“Toda planta que receber luz exatamente no seu ponto de compensação irá consumir na respiração toda a glicose e todo o oxigênio produzidos pela fotossíntese. Assim também o gás carbônico liberado pela respiração será utilizado pela fotossíntese. Pode-se concluir que se a planta for mantida no seu ponto de compensação ou abaixo dele não terá condições de sobreviver, considerando que não haverá disponibilidade de alimento para a sua manutenção nos períodos de ausência de luz, ou seja, sem fotossíntese.” (SCHAMBACH, 2014, p. 137 e 138)

Do contrário, havendo intensidade luminosa acima do ponto de compensação luminoso, a planta produzirá glicose e oxigênio acima do seu consumo, mantendo o crescimento como é ilustrado na FIGURA 6 – Ponto de compensação fótico (SCHAMBACH, 2014).

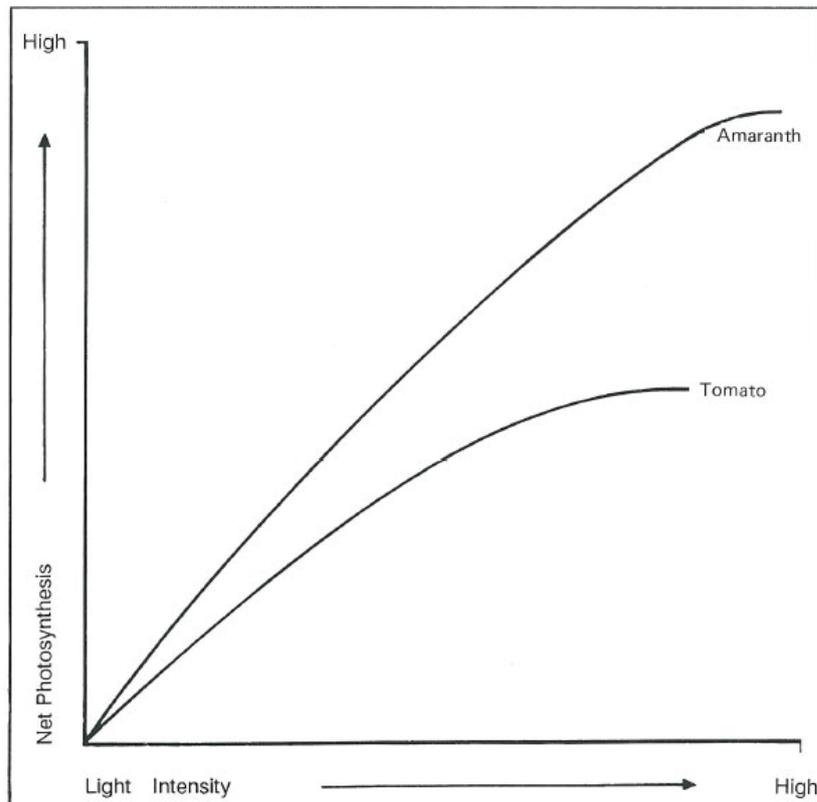
FIGURA 6 – Ponto de compensação fótico



FONTE: SCHWAMBACH (2014)

Em seguida também é importante observar que a fotossíntese é influenciada de forma diferente pela intensidade de luminosidade disponível para a diversidade de espécies (FIGURA 7).

FIGURA 7 – Resposta da fotossíntese ao incremento de luminosidade para diferentes espécies



FONTE: AVRDC (1990)

2.1.1.3 Pluviosidade

Segundo NOVAIS (2007), a água é fator fundamental na produção vegetal, sendo que as culturas durante o seu ciclo vegetativo e reprodutivo consomem enorme volume de água, notando-se que cerca de 98% deste volume passa pela extensão da planta.

A chuva é a principal fonte natural de água, porém outras fontes naturais também são importantes, como por exemplo, o orvalho. No entanto, a quantidade absorvida também é diferenciada em detrimento da fonte, o orvalho citado, tem sua absorção dada pelos estômatos e assim a quantidade absorvida é reduzida.

Como indicado anteriormente, a água é um dos grandes fatores que alteram a produtividade das plantas, principalmente a sua falta, isso é explicado por as plantas serem compostas em torno de 80 a 95% - visualiza-se na figura FIGURA 8 - Água encontrada comumente em diferentes plantas e suas partes - dessa substância, enquanto que o restante deve ser produzido e composto através de fotossíntese, mesmo deixando de lado a questão da biomassa, a água é essencial para o crescimento e desenvolvimento (AVRDC, 1990).

Para NOVAIS (2007), no processo de absorção de nutrientes, a água é, provavelmente, o fator com maior influência devido à concentração e ao contato de nutrientes com a solução do solo provido com a superfície da raiz através do mecanismo de fluxo de massa.

FIGURA 8 - Água encontrada comumente em diferentes plantas e suas partes

Parte da Planta	Peso Fresco (%)
Frutos de pepino	96
Cabeça de alface	94
Cabeça de repolho	90
Tubérculo de batata	79
Folhas de tomate	85-95
Folhas de milho	65-82
Raízes de cenoura	88
Tipos de aspargo	88
Frutos de tomate	94
Sementes de milho doce	85

FONTE: AVRDC (1990)

Uma das principais funções da água para os vegetais é a manutenção da temperatura, possibilitando a não inativação das enzimas da fotossíntese e da respiração e o forte relacionamento com o arrasto de nutrientes que se dá pelo gradiente do solo às partes aéreas quando da transpiração.

Destaca-se também que a água é o principal fator que determina a eficiência nutricional e, conseqüentemente, a produtividade das culturas. Em geral, a maioria das plantas cultivadas, são mais sensíveis às deficiências hídricas no período de uma semana que antecede a floração (NOVAIS et. al., 2007).

Também há o contraponto de excesso de chuva, onde se pode ter como efeito adverso a erosão e alagamento. A erosão laminar resulta no escoamento dos nutrientes presentes na superfície do solo. Já o alagamento resulta em alterações nas reações que acontecem no solo, passando-o para condições anaeróbias. Em alguns casos de alagamento, o elevado nível de decomposição orgânica eleva o subproduto metano a níveis tóxicos que não permite as plantas de manter suas atividades para nutrição e por conseqüência de realizar a fotossíntese. Os efeitos apresentados são maior suscetibilidade a doenças e formação de compostos

químicos tóxicos a maioria das plantas. Ainda, solos inundados possuem tipicamente uma grande quantidade de dióxido de carbono, esse por sua vez reduz juntamente com os poros tomados por água a permeabilidade ou ainda, a capacidade de a raiz angariar água.

Os efeitos adversos da inundação do solo se intensificam à medida que a temperatura se eleva em decorrência do aumento de velocidade na respiração das raízes, alta demanda de água e redução da habilidade do oxigênio se dissolver na mesma (AVRDC, 1990).

Outros componentes que influenciam na absorção da água podem ser citados, como por exemplo a alta concentração de sais no solo, que podem limitar o fluxo de água e a densidade do solo que pode favorecer ou não o crescimento das raízes e contato com a umidade disponível.

Segundo AVRDC (1990), em situações de seca, caso a planta não tenha desenvolvido um sistema de raízes estável antes da instalação do período seco, a mesma não consegue sobreviver exceto quando irrigada ou caso seja uma cultivar resistente a seca. Complementa que caso a ocorrência dessa seca acontecer em um ou mais períodos críticos de desenvolvimento da planta, normalmente há perda direta e significativa de produção.

O estágio crítico de impacto do estresse hídrico também varia de espécie à espécie como é possível verificar na tabela.

TABELA 1 - Estágios críticos ao estresse hídrico para diversas espécies

Cultura	Estágio crítico
Feijão	Floração e formação de vagens
Repolho	Formação e ampliação da cabeça
Cenoura	Alargamento da raiz
Berinjela	Floração e ampliação de frutas
Alface	Cabeça em desenvolvimento
Ervilha	Floração e enchimento de vagens
Batata	Qualquer período de crescimento desde o plantio até a colheita
Melancia	Floração para frutificação

FONTE: Adaptado de AVRDC (1990)

NOVAIS (2007) lembra que em plantas com restrições no crescimento do sistema radicular, há redução de produtividade mais expressiva em regiões onde ocorrem períodos de estiagem durante seu cultivo.

2.1.1.4 Ventos

Apesar de contrariar o senso comum, os ventos também são essenciais, na medida correta, ao pleno funcionamento do ecossistema em que as plantas são expostas. O principal efeito é dado pela rápida reposição de dióxido de carbono na superfície da planta, visto que durante o crescimento da planta, rapidamente se possui o esgotamento desse composto das superfícies da folha. AVRDC (1990) explica esse efeito:

“When there is no Wind, the rate of resupplying the surface of the leaf is limited, so entry of CO₂ is too slow to maintain rapid photosynthesis. Wind also carries O₂ away from the plant. On the other hand, when there is less Wind, there is less evaporation and less water requirement”.

Também, o mesmo autor, pontua que, existe uma grande limitação em função do vento em regiões onde se vislumbra ocorrência frequente de ventos com velocidade média de em torno de 7,2km/h.

Para algumas espécies vegetais também é crítica o estresse ao vento e normalmente se possui grande quebra de produção em situações de crescimento da planta concluído sendo o principal fator o acamamento. O mesmo efeito é observado de outra forma por AVRDC (1990):

“All vegetable crops, except the tree vegetables, are very susceptible to Wind speeds greater than the ordinary. The deeper the root system of the crop, generally the more resistant it is to strong winds. Varieties that are early-maturing have a better chance of harvested before the onset of strong winds than late-maturing ones”.

2.1.2 Solo

Quando identificamos o solo como fator de influência no crescimento e desenvolvimento de plantas, incluímos na discussão fatores de natureza física como a estrutura, textura, densidade e umidade do solo, bem como fatores de naturezas químicas e biológicas (NOVAIS, 2007).

Segundo AVRDC (1990), uma das principais funções do solo é ser um reservatório de água e de nutrientes para a planta. As suas características físicas e químicas influenciam diretamente no crescimento das plantas.

Os fatores de natureza física do solo são propriedades que podem influir acentuadamente no crescimento das plantas, pois estão intimamente associadas à estrutura e textura do solo. Dentre esses fatores estão a densidade, espaço poroso,

umidade, taxa de infiltração de água e a erodibilidade. A estrutura do solo tem como indicador a distribuição física do solo em agregados – torrões, em outras palavras, definem-se como a distribuição espacial do solo. Já a textura se refere a distribuição das partículas de acordo com o seu tamanho, também expressa a proporção relativa de partículas de areia, de silte e de argila que compõe a terra fina do solo (NOVAIS, 2007).

A densidade do solo por sua vez possui ligação íntima com os dois quesitos anteriormente citados: textura e estrutura. Uma vez que havendo menor espaço/arejamento entre as partículas, ou seja, estrutura compacta, maior será a densidade. Segundo NOVAIS (2007), o aumento de densidade do solo reduz a taxa de difusão de O_2 nos poros do solo e, conseqüentemente, a respiração das raízes. A densidade do solo também está associada ao volume de água disponível e resistência a penetração das raízes devido à compactação.

Percebe-se então que o sistema de manejo adotado é fundamental para possibilitar boas características ao solo, uma vez que, por exemplo, no sistema convencional, pelo intenso tráfego de equipamentos, naturalmente haverá maior compactação. Além é claro, do próprio favorecimento de palhada, como é afirmado por NOVAIS (2007):

“O sistema de manejo do solo pode afetar acentuadamente sua umidade. A cobertura de um Argissolo com resíduos culturais de palha de trigo ($7,5t\ ha^{-1}$ de palha), durante o mês de novembro, manteve em torno de $100g\ kg^{-1}$ a mais de água que o mesmo solo descoberto”.

“When a previously forested land area is used for growing vegetables for the first time, the soil usually contains all the nutrient elements that the plant needs, However, as it is continuously used for producing a crop, the amount of nutrient elements decreases to levels which are not enough to support growth and development. Without the use of fertilizer, the yield is expected to decrease” (AVRDC, 1990, p. 72).

O autor ainda explica que os nutrientes no solo não estão sempre imediatamente disponíveis, podendo ocorrer os sintomas de deficiência mesmo com elevados níveis de determinado elemento no solo.

Os nutrientes que as plantas requerem podem ser classificados como essenciais quando a planta não completa seu ciclo sem a presença dos mesmos em concentrações mínimas necessárias. De outra maneira, se classificam como benéficos quando acrescentam boas características a produção ou a aumentam.

Quanto à quantidade necessária, os requeridos em elevada quantidade são os macronutrientes e os em menor quantidade requisitados, são os micronutrientes.

“The macroelements are nitrogen, phosphorus, potassium, sulfur, calcium, and magnesium. There are microelements: boron, copper, chlorine, manganese, molybdenum, zinc, and iron. Carbon, hydrogen, and oxygen are obtained from CO₂ and water are not mineral nutrients” (AVRDC, 1990, p. 72).

As funções e sintomas de deficiência dos macronutrientes podem ser resumidos conforme tabela:

TABELA 2 – Funções e sintomas de deficiência dos macronutrientes

Nutriente	Função na planta	Sintoma de deficiência
Nitrogênio (N)	Síntese de proteínas (incluindo enzimas), clorofila, e cromossomos	Verde claro para amarelado iniciando nas folhas inferiores, plantas menores que o normal
Fósforo (P)	Componente da ATP e outros reagentes na fotossíntese e respiração, componente da membrana celular	Haste e folhas com tom roxos/púrpura, plantas menores que o normal
Potássio (K)	Importante no metabolismo de carboidrato e proteínas, ativação de certas enzimas, promoção do crescimento do tecido meristemático, importante para o movimento do estômato e relacionamento com a água	Produção decresce sem sintomas visíveis, plantas menores que o normal, margem das folhas podem se tornar bronzeadas/tom marrom em casos severos
Cálcio (C)	Componente da lamela média associado com atividade de certas enzimas	As folhas novas não saem ou, se o fazem, não se desdobram, tendem a se agarrar; raízes apicais também não se desenvolvem; amarelecimento das margens das folhas mais

		jovens
Magnésio (Mg)	Componente da molécula da clorofila, necessária para a ativação de certas enzimas	Folhas velhas apresentam verde claro ou ficam amareladas, normalmente entre os veios
Enxofre (S)	Componente de muitas proteínas e vitaminas, ativador de algumas enzimas requeridas para fixação de N em plantas leguminosas	As plantas apresentam amarelo uniforme, ou ainda verde claro, com hastes finas e espinhosas; plantas menores que o normal

FONTE: adaptado de AVRDC (1990)

Para os micronutrientes, a deficiência é mais incomum, em decorrência da própria quantidade requerida pelas plantas, no entanto, no caso de ocorrência de deficiência, a redução de produção é bastante significativa. Um resumo das funções e sintomas de deficiência é apresentado na tabela:

TABELA 3 – Funções e sintomas em caso de deficiência, nas plantas, dos micronutrientes

Nutriente	Função na planta	Sintoma de deficiência
Boro (B)	Divisão celular, estabilidade da parede celular, germinação e crescimento do pólen, translocação de açúcares	Na couve-flor as folhas jovens se tornam amarelas e a haste é oca
Cobre (Cu)	Síntese e estabilidade da clorofila, metabolismo de proteínas e carboidrato, fixação de N	Folhas jovens murchas e enroladas, redução da lignificação; abortamento de número de flores.
Cloro (Cl)	Fotossíntese e balanço de água	Difícilmente visíveis em situações de campo, no entanto, são: redução do tamanho das folhas, clorose seguida de bronzeado, evoluindo para necrose,

		tendendo-se a enrolar
Ferro (Fe)	Síntese de clorofila, redução de nitrato e síntese de proteínas	Folhas jovens cloróticas, algumas vezes de cor branca
Manganês (Mn)	Participante de enzimas envolvidas na respiração e processos de oxidação-redução na fotossíntese	Cloroses entre as nervuras de folhas novas e velhas podendo ocorrer lesões necróticas
Molibdênio (Mo)	Componente das enzimas nitrogenase e nitrato-redutase	Folhas ainda verde deformam-se em decorrência de morte de células no parênquima
Zinco (Zn)	Síntese de hormônios, ajustes na oxidação e redução	Redução de atividade enzimática, desenvolvimento de cloroplastos, conteúdo de proteínas e ácidos nucleicos

FONTE: adaptado de AVRDC (1990)

Também é apontado por NOVAIS (2007) a importância da correção do solo em termos de acidez nos solos brasileiros, sendo estabelecida como uma limitação ao cultivo nesses solos em decorrência da presença de Al e Mn em concentrações tóxicas e de baixo teor de cátions de caráter básico, como Ca e Mg.

“A acidez do solo condiciona o estado geral do solo como base de crescimento para as plantas, em decorrência das relações de causa e efeito com outras propriedades químicas, físicas e biológicas. Essas propriedades relacionam-se com a gênese, mineralogia e fertilidade do solo e têm, em última análise, implicações no seu manejo. Assim, a acidez do solo, quando em excesso, pode ocasionar alterações na química e fertilidade, restringindo o crescimento de plantas” (NOVAIS, 2007, p. 206).

A calagem – correção de acidez do solo - pode ser dita como um dos pilares para obtenção de melhores produções agrícolas em solos ácidos pois com ela estamos anulando ou diminuindo os efeitos tóxicos das altas concentrações de Al e Mn, além de fornecer dois macronutrientes Ca e Mg (NOVAIS, 2007).

Importante ressaltar que a necessidade de correção do solo está relacionada com o pH e também ao PTH – poder tampão do solo, cabendo a inserção de que o PTH está relacionado diretamente aos teores e tipos de argila e de matéria orgânica

do solo. Pode-se explicar de breve maneira, que o PTH é considerado como uma espuma, o quanto o solo pode absorver, sendo assim, quanto maior for o poder de tampão do solo, maior será a necessidade de material para correção para o mesmo acréscimo de pH comparativamente a um solo com menor PTH. Pode-se observar a faixa de pH ótimo do solo para alguns vegetais na tabela:

TABELA 4 - Faixa ótima de pH para algumas culturas

pH do solo	Cultura	pH do solo	Cultura
> 6,5	Alfafa, Aspargo Piretro, Trevo doce, Beterraba Açucareira	5,0 – 5,5	Batata, Fumo, Cerejas
5,5 – 6,5	Trevo Vermelho, Milho, Soja, Sorgo, Trigo, Cevada, Macieira, Pereira	< 5,0	Azaléia, Hortências, Erva Mate, Mandioca

FONTE: adaptado de NOVAIS (2007)

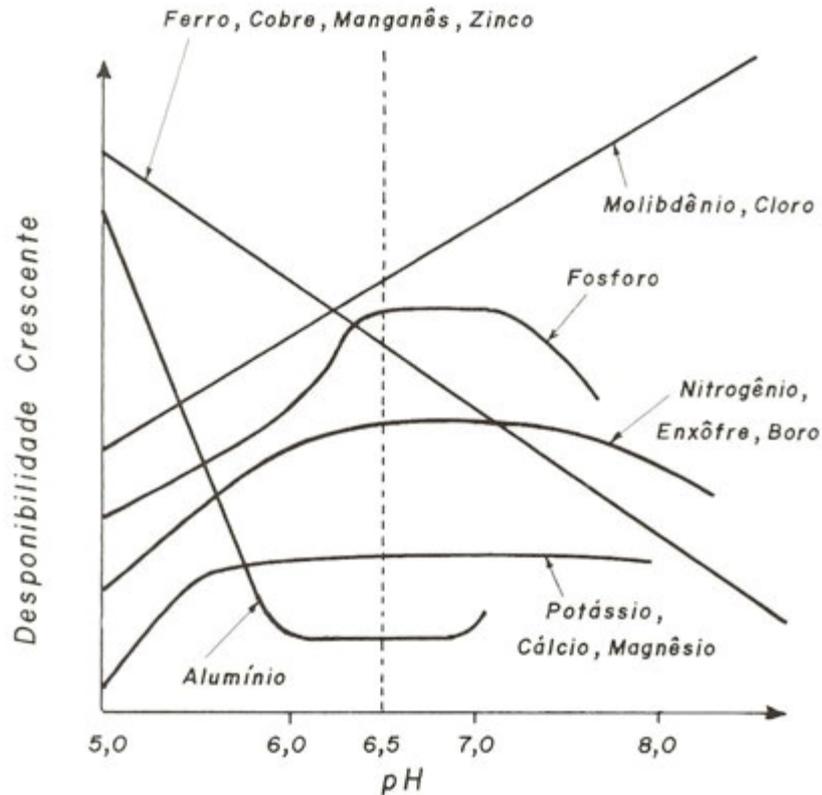
A influência do pH na disponibilidade dos nutrientes pode ser verificada na figura FIGURA 9 – Disponibilidade dos nutrientes em função do pH. Podemos observar que há um aumento na disponibilidade dos nutrientes Molibdênio e Cloro, enquanto um decréscimo para o Ferro, Cobre, Manganês e Zinco pelo crescente pH. Já para os nutrientes P, N, S e B há um acréscimo de disponibilidade com decréscimo a partir do pH sete aproximadamente, para o Fósforo, a linha é mais acentuada. Notadamente há um decréscimo acentuado na disponibilidade do Alumínio até próximo ao pH seis, com suave retomada no pH sete em contraponto o Potássio, Cálcio e Magnésio possuem um acréscimo até em torno de 5,5 e posterior estabilidade em sua disponibilidade.

Como citado por NOVAIS (2007) um dos subfatores considerados no fator solo é a matéria orgânica que representa o resto de plantas e animais em vários estágios de decomposição. Dessa forma, as partículas podem apresentar-se de diferentes tamanhos e formas - estrutura (AVRDC, 1990).

A matéria orgânica é provedora de nutrientes em longo prazo, ou seja, pode ser considerada como uma fonte de macronutrientes, a exemplo do N e S, e de

micronutrientes, mas não para efeitos corretivos, pois tem disponibilização lenta dos nutrientes.

FIGURA 9 – Disponibilidade dos nutrientes em função do pH



FONTE: CAFEPPOINT (2019)

Como subfator solo também se tem a presença excessiva de sais, os quais, em elevada concentração podem reduzir de 10 a 50% a produção do cultivo. Outro efeito adverso da presença excessiva de sais é a redução da quantidade de água disponível às plantas, nesses casos, normalmente recorre-se a irrigação (AVRDC, 1990).

2.2 INTELIGÊNCIA ARTIFICIAL

Antes de falarmos sobre inteligência artificial, é importante definir inteligência:

“O teórico da aprendizagem Jean Piaget (...) conceitua inteligência com base nas interações do indivíduo com o ambiente, envolvendo um equilíbrio entre a assimilação (incorporação dos aspectos do ambiente à aprendizagem prévia) e a acomodação (mudança comportamental diante das demandas do ambiente). O resultado dessa interação, de acordo com Piaget, é o desenvolvimento de estruturas cognitivas, esquemas e operações que refletem no comportamento do indivíduo.” (MEDEIROS, 2008, p.18).

Segundo MEDEIROS (2008), as principais características da inteligência são:

- Capacidade de resolução de problemas;
- Aprendizado com o ambiente;
- Desenvolvimento de estruturas cognitivas; e
- Orientação a metas.

Entendendo então que a inteligência corresponde a capacidade de resolver problemas ou de elaborar produtos que sejam importantes em determinado ambiente (MEDEIROS, 2008), passamos a definição de inteligência artificial, na qual, MEDEIROS (2008) afirma que não há um consenso na comunidade científica quanto a essa definição, isso é explicado no trecho adiante:

“Existe uma série de elementos que se manifestam de maneiras diferenciadas e também em razão de interpretações distintas sobre como os processos de IA se correlacionam com os mecanismos do cérebro e da mente humana.” (MEDEIROS, 2008, p.19).

No entanto, segundo FRANCO (2004), alguns autores entendem que podemos dizer que é o ramo da ciência da computação que se ocupa da automação do comportamento inteligente.

É importante destacar que é uma matéria multidisciplinar, pois o que hoje conhecemos como inteligência artificial (IA) é um ramo da ciência da computação ao mesmo tempo recente e antigo, cujos princípios baseiam-se em ideias filosóficas científicas e tecnológicas herdadas de outras ciências (FRANCO, 2004).

Dentro desse enfoque, se pode classificar a IA, segundo FRANCO (2004), em quatro grandes grupos:

- Sistemas que pensam como humanos;
- Sistemas que atuam como humanos;
- Sistemas que pensam racionalmente; e
- Sistemas que atuam racionalmente.

Dessa forma, pensar se refere aos mecanismos implícitos existentes no cérebro (na mente), enquanto agir se refere à manifestação no mundo real de um comportamento inteligente (MEDEIROS, 2008).

Como visto anteriormente, a IA é influenciada e composta por múltiplas disciplinas com abordagens variadas, assim, levou à distinção em duas linhas de pesquisa:

“Se assumirmos a perspectiva que prioriza o cérebro com seus elementos mais básicos, os neurônios e as sinapses que os conectam, nosso principal desejo é construir cérebros artificiais, com neurônios artificiais que simulem a maneira como os mecanismos eletroquímicos dos cérebros biológicos funcionam. Mas quando adotamos uma perspectiva centrada na mente, que atua com base no processamento de símbolos, como um software executado sobre um hardware (cérebro fisiológico), então, nosso desejo mais decisivo é construir dispositivos que lidem com tais símbolos da mesma forma como a mente humana os processa.” (MEDEIROS, 2008, p.22).

Para o primeiro caso denominamos de conexionista, no qual simulamos as células biológicas que interagem para a ocorrência de inteligência, nessa linha os principais modelos são de desenvolvimento de redes neurais artificiais (RNA) e sistemas imunológicos artificiais (MEDEIROS, 2008).

Já para o segundo, é conhecida como simbólica, buscando lidar com processos inteligentes utilizando linguagens baseadas em lógica e na construção de redes semânticas, solucionando problemas e simulando conhecimento (MEDEIROS, 2008).

2.2.1 Aprendizagem de Máquina

Importante conceituar também a capacidade de aprendizado com o ambiente, que no contexto de IA é dita como aprendizado de máquina (AM): “A capacidade de melhorar o desempenho na realização de alguma tarefa por meio da experiência” (FACELI, 2011).

“Em AM, computadores são programados para aprender com a experiência passada. Para tal, empregam um princípio de inferência denominado indução, no qual se obtêm conclusões genéricas a partir de um conjunto particular de exemplos. Assim, algoritmos de AM aprendem a induzir uma função ou hipótese capaz de resolver um problema a partir de dados que representam instâncias do problema a ser resolvido. Esses dados formam um conjunto, simplesmente denominado conjunto de dados.” (FACELI, 2011, p.3).

Algoritmos de AM precisam ser capazes de lidar com dados imperfeitos, com a presença de ruídos, dados inconsistentes, ausente ou mesmo redundantes (FACELI, 2011).

Quanto a dados, podemos ainda nos referir as entradas dos algoritmos que devem ser, dentro do possível, considerados atributos que possuem influência com

a regra ou função que se pretende induzir, assim, os demais não devem ser considerados.

Já a quantidade de dados tem influência na capacidade de generalização, ou seja, para quantos casos reais, não treinados, haverá correspondência ou boa aproximação de resultado. Nesse viés é possível se ter baixa capacidade de generalização por estar superajustada aos dados (*overfitting*), onde se diz que a hipótese memorizou ou se especializou nos dados de treinamento. Já no caso inverso, há possibilidade de induzir hipóteses com baixa taxa de acerto – subajustamento (*underfitting*), um exemplo que acarreta o subajustamento são casos de poucos exemplos de treinamento ou onde são pouco representativos (FACELI, 2011).

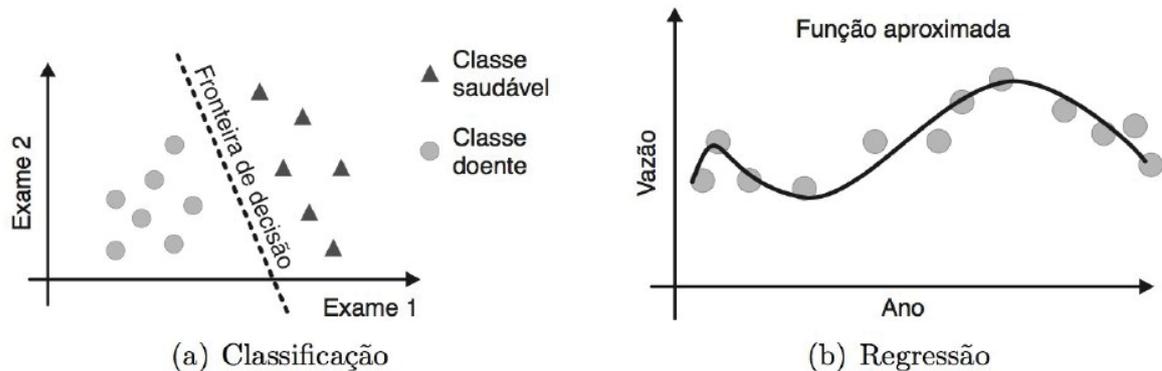
“Quando um algoritmo de AM está aprendendo a partir de um conjunto de dados de treinamento, ele está procurando uma hipótese, no espaço de possíveis hipóteses, capaz de descrever as relações entre os objetos e que melhor se ajuste aos dados de treinamento. Cada algoritmo utiliza uma forma ou representação para descrever a hipótese induzida. Por exemplo, redes neurais artificiais representam uma hipótese por um conjunto de valores reais, associados aos pesos das conexões da rede.” (FACELI, 2011, p.5).

As tarefas de aprendizado podem ser divididas em dois grupos, as tarefas preditivas e as descritivas.

“No primeiro grupo, tarefas de previsão, a meta é encontrar uma função a partir dos dados de treinamento que possa ser utilizada para prever um rótulo ou valor que caracterize um novo exemplo, com base nos valores de seus atributos de entrada. Para isso, cada objeto do conjunto de treinamento deve possuir atributos de entrada e saída. (...) Esses algoritmos seguem o paradigma de aprendizado supervisionado” (FACELLI, 2011, p.6).

Já para tarefas de descrição a dedicação se dá em explorar, ou ainda, descrever um conjunto de dados. Visualmente a diferença entre os dois tipos de tarefas é vista na figura.

FIGURA 10 – Classificações das tarefas, à esquerda, descrição e a direita a representação é da predição



FONTE: FACELLI (2011)

O termo supervisionado se dá por existir um valor de saída correspondente aos valores de entrada no conjunto de dados de treinamento.

2.2.2 Conjunto de dados

Conjuntos de dados são formados por objetos, esses por sua vez representam uma noção abstrata, essa noção abstrata normalmente é dada por um conjunto de características também chamado de atributos de entrada. Um objeto representa uma ocorrência de dados e cada atributo está relacionado a uma propriedade do objeto (FACELLI, 2011).

Segundo FACELLI (2011), na maioria das vezes não é possível utilizar algoritmos de AM diretamente nas bases de dados disponíveis. Esses dados frequentemente necessitam de um pré-processamento, também indica que as técnicas podem ser agrupadas como:

- Eliminação manual de atributos;
- Integração de dados;
- Amostragem de dados;
- Balanceamento de dados;
- Limpeza de dados;
- Redução de dimensionalidade; e
- Transformação de dados.

Um dos principais entraves de desempenho na utilização dos algoritmos de AM é mesmo a utilização das técnicas acima expostas, a presença de um número

muito grande de atributos, de atributos redundantes, irrelevantes e/ou inconsistentes (FACELLI, 2011).

O principal questionamento até esse momento então passa a ser:

“How can we be sure that our learning algorithm has produced a hypothesis that will predict the correct value for previously unseen inputs? In formal terms, how do we know that the hypothesis h is close to the target function f if we don't know what is?” (RUSSEL, 2010, p. 713).

A resposta desse questionamento está fortemente ligada a teoria do aprendizado computacional, o princípio subjacente de resposta a pergunta é:

“any hypothesis that is seriously wrong will almost certainly be “found out” with high probability after a small number of examples, because it will make an incorrect prediction. Thus, any hypothesis that is consistent with a sufficiently large set of training examples is unlikely to be seriously wrong: that is, it must be probably approximately correct.” (RUSSEL, 2010, p. 714).

Para se ter noção da dimensão da quantidade de exemplos de treinamento necessários para um dado problema RUSSEL (2011) nos indica a seguinte função:

$$N \geq \frac{1}{\epsilon} (\ln \frac{1}{\delta} + \ln |\mathcal{H}|), \text{ onde:}$$

N : quantidade de exemplos de treinamento;

ϵ : erro formal esperado;

δ : constante que representa a probabilidade de ocorrência de erro; e

\mathcal{H} : espaço de hipótese.

O autor ainda exemplifica o crescimento da complexidade da amostra do espaço de hipótese, indicando que se o espaço da hipótese for um conjunto de todas as funções booleanas sobre n atributos então a complexidade da amostra cresce em 2^n . Dessa forma o número de exemplos possíveis também é da mesma dimensão 2^n .

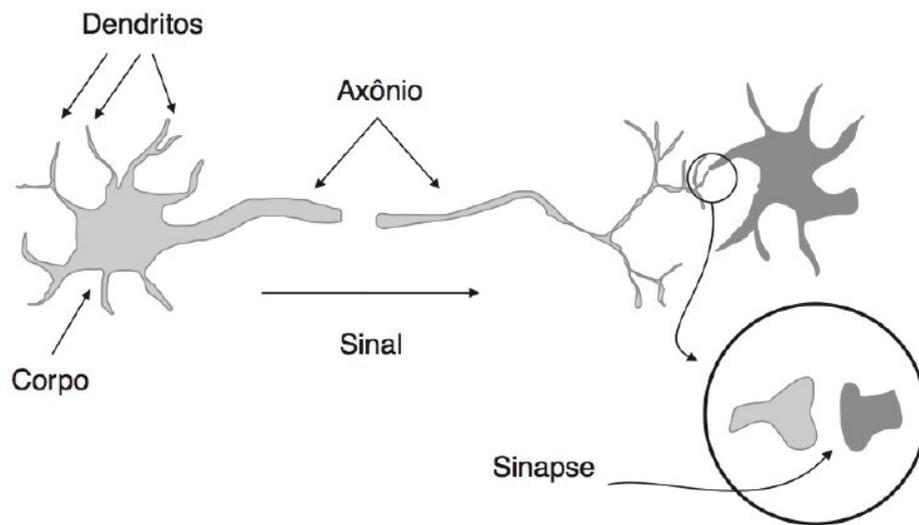
2.2.3 Redes Neurais Artificiais

Como citado anteriormente, o método de RNA utiliza o conceito biológico de neurônio. Esses podem ser definidos como elementos de processamento muito simples, compostos por um soma – seu corpo, um axônio e vários dendritos (FRANCO, 2014).

O funcionamento do neurônio é dado pela recepção de estímulos de por meio dos dendritos advindos de outros neurônios. Esses estímulos são transmitidos para o corpo, que os combina e processa, a depender da intensidade e frequência do

estímulo. Esse corpo gera novo impulso, enviado ao axônio e realizando contato com o próximo neurônio. A transmissão entre neurônios se chama de sinapse, e esse modelo está ilustrado na figura FIGURA 11 – Modelo de neurônio biológico simplificado (FACELLI, 2011).

FIGURA 11 – Modelo de neurônio biológico simplificado



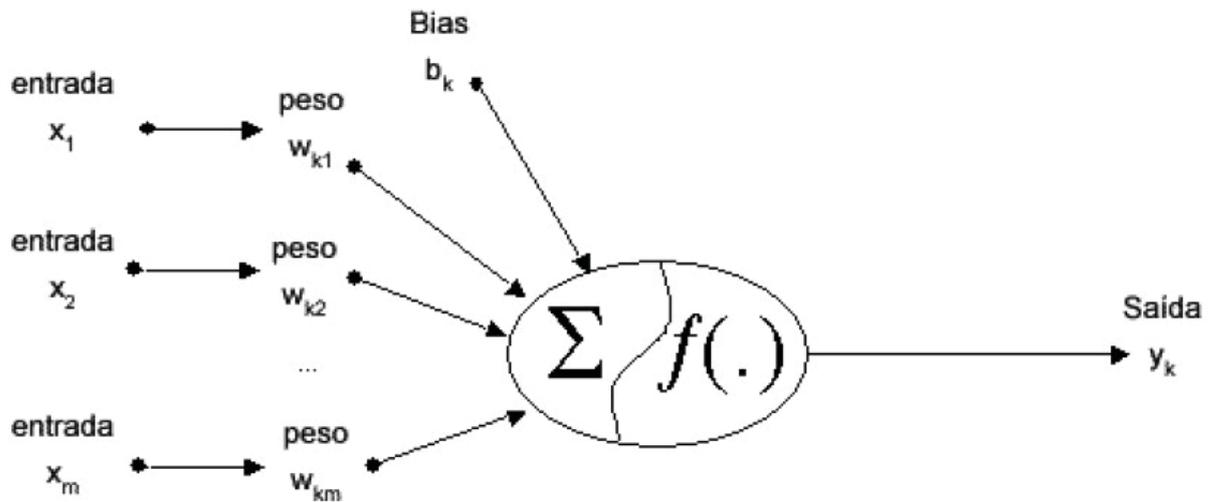
FONTE: FACELLI (2011)

Dessa forma, se conceitua as RNAs como sistemas computacionais distribuídos compostos de unidades de processamentos simples, densamente interconectadas, essas unidades – neurônios artificiais – computam funções matemáticas (FACELLI, 2011).

O modelo de um neurônio artificial pode ser visto a seguir (FIGURA 12 – Modelo de neurônio artificial):

“Nessa figura, o neurônio é representado através de suas entradas (x), seus pesos para cada entrada (w), seu corpo e sua saída (y). O corpo é dividido em duas partes, sendo a primeira responsável por somar o produto das entradas por seus respectivos pesos e a segunda responsável por controlar o valor da saída (y) através de uma função de ativação ou transferência. Além das entradas regulares (x), é prevista uma entrada extra chamada de bias (b) que, embora não esteja presente nos neurônios biológicos, pode ser útil em várias situações, pois aumenta os graus de liberdade e a adaptação da rede ao conhecimento a ela fornecido” (FRANCO, 2014, p.99).

FIGURA 12 – Modelo de neurônio artificial



FONTE: FRANCO (2014)

Segundo FRANCO (2014), a fórmula da primeira parte do processamento pode ser representada por $V_j = \sum_{i=1}^m w_{ji}x_i + b$, onde:

V : valor de ativação do neurônio k ;

w : pesos das conexões do neurônio k ;

x : valor de cada um dos m estímulos que chegam ao neurônio k ; e

b : valor do bias que será somado ao valor do combinador linear para compor o valor de ativação.

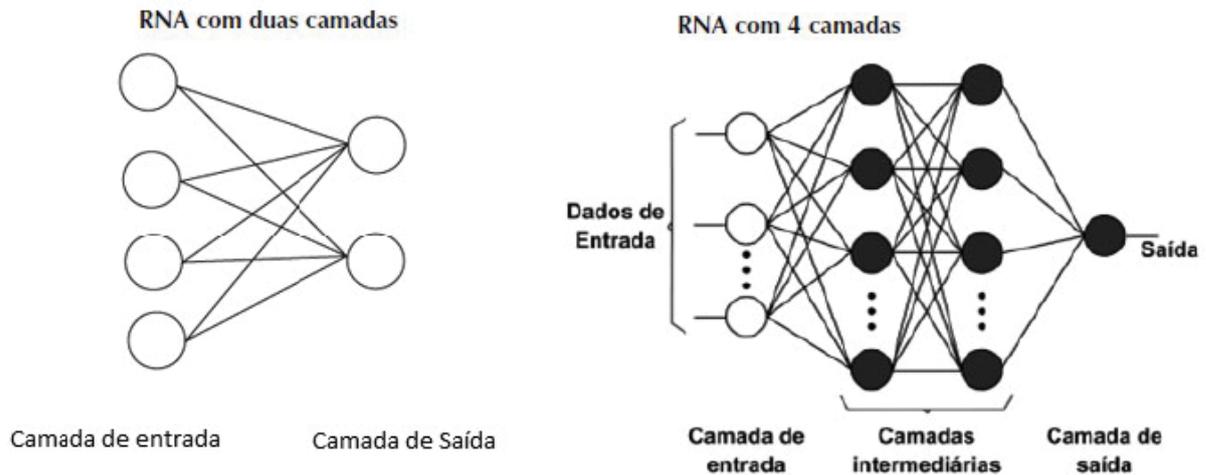
Os neurônios artificiais podem ser dispostos em duas – entrada ou saída - ou mais camadas interligadas – com camadas intermediárias - por um grande número de conexões, a representação das camadas pode ser verificada na figura FIGURA 13 – Redes neurais com duas e quatro camadas. Essas conexões simulam as sinapses biológicas e, em geral, possuem pesos associados que ponderam as entradas recebidas por cada neurônio (FACELLI, 2011).

FRANCO (2014) explica que, na camada de entrada – a primeira – cada nó recebe um sinal de entrada único e não processam informações, somente as repassam as camadas seguintes, já nessas, é onde realmente acontece o trabalho de ajuste de pesos quando um erro é cometido para um fragmento de dados de treinamento.

Segundo RUSSEL (2011), a principal complicação quanto ao erro vem da adição de camadas ocultas – intermediárias - da rede, pois para a camada de saída o erro é claro, no entanto, nas camadas ocultas parece misterioso por que os dados de treinamento não dizem que valor os nós ocultos devem ter. Porém, o mesmo

autor também indica que podemos retropropagar o erro da camada de saída para as camadas ocultas através de uma derivação do gradiente de erro geral, esse efeito na literatura é conhecido como “*backpropagation*”.

FIGURA 13 – Redes neurais com duas e quatro camadas



FONTE: adaptado de FRANCO (2014)

Depreende-se, pelo já visto até o momento, que uma maior quantidade de camadas possibilita um maior ajuste quanto à curva de função – funções mais complexas podem passar a ser criadas, no entanto, há aumento considerável de consumo computacional. Esse processo é confirmado por RUSSEL (2011), quando nos informa que a função representada por uma rede (RNA) pode ser altamente não linear, composta por funções de limiar suave não lineares aninhadas, sendo assim vista como uma ferramenta para regressão não linear.

Para se projetar uma RNA é necessário definir a quantidade de camadas, quantidade de neurônios em cada camada e a forma de conexão entre os neurônios – essas são as interdependências que devem ser definidas pelo especialista e são próprias do problema. Para a camada de entrada, deve-se usar um neurônio para cada atributo (FRANCO, 2014).

Já para a camada oculta, FRANCO (2014) alerta que, não existe regra universal, e o projeto consiste geralmente em tentativa e erro. Ainda, indica ainda que, quando uma rede não apresenta bom desempenho, é prática comum refazer todo o projeto alterando os parâmetros (camadas, neurônios, conexões etc.) com base na tentativa e erro.

Quanto ao processo de treinamento da rede, FRANCO (2014) lembra que é um processo delicado, pois não deve ser treinada 100% para cada fato a ser

reconhecido, mas com um conjunto inteiro, apresentadas as entradas várias vezes iterativamente em decorrência do fenômeno já tratado de *overfitting*.

Atualmente a utilização de algoritmos de RNA está facilitada em vista da disponibilidade de várias “*frameworks*” – uma solução para uma família de problemas semelhantes (UFSC, 2019) – inclusive gratuitas. Algumas delas são TensorFlow, PyTorch, Sonnet, Keras e MXNet. Efetivamente não é necessária a programação do algoritmo de RNA e sim, seu entendimento básico de funcionamento e seus princípios, além, da modelagem e disponibilização de dados no formato aceito pela “*framework*” escolhida. Doutra maneira, também facilmente são encontrados algoritmos prontos para uso em diversas linguagens de programação.

3 RESULTADO E DISCUSSÃO

Foram apresentados na revisão bibliográfica efetuada os fatores que influenciam o crescimento e desenvolvimento das plantas. Contudo, como se pode verificar, é de grande extensão a gama e interdependência dos fatores. Além disso, os fatores variam em função da espécie de planta, ou seja, uma espécie dita as condições ambientais e de solo em qual possui desempenho ótimo.

Sobre a interdependência dos fatores, normalmente não se considera como um problema no desenvolvimento de uma rede neural, ao menos não para esse tipo, com retroalimentação – retropropagada, tendo em vista que haverá o aprendizado e correção dos pesos com base no conjunto de dados de teste.

Cabe ressaltar que alguns desses fatores como níveis de nutrientes no solo, já são manejados pelo homem para a grande maioria das espécies cultivadas. Já outros fatores como pluviosidade e temperatura só podem ser controlados para espécies de pequeno porte com cultivo em sistema protegido (casa de vegetação), como é o caso dos sistemas hidropônico e de estufa irrigada. Dessa forma é perceptível que os fatores também são influenciados fortemente pelo sistema de produção.

Outra percepção é tratada pela quantidade desses fatores que mesmo não sendo todos citados de forma minuciosa no trabalho, podem modificar o resultado da RNA proposta. Uma das formas que pode ser modificada pela quantidade de fatores, considerando apenas os que foram apontados, é da dificuldade de recolher os dados com uma mesma metodologia, a fim de serem comparáveis entre si, e em período de tempo aceitável.

Sendo assim, para cada espécie de planta e sistema de cultivo se faz necessário o estudo do conjunto de fatores de influência que farão parte do modelo de RNA.

Foi feita pesquisa complementar no sentido de localizar bases de dados que compreendam minimamente os fatores levantados ou que poderiam ser manobradas a fim de algum resultado. No entanto, sequer foram localizadas bases de dados que poderiam ser consideradas para alguma extração de informação.

Ainda sobre o recolhimento dos dados, é importante lembrar que poderíamos reduzir o espaço de hipótese, sendo assim, haveria a possibilidade de uma convergência com menor quantidade de dados. Para tanto, se faz necessário

que a coleta dos mesmos tenha no mínimo condições parecidas de alguns desses fatores, por exemplo, e qualidade mineralógica do solo, manejo aplicado e espécie cultivada.

Já ficam claras algumas necessidades, dentre elas a metodologia de padronização das coletas de dados, a localização de produtores que contemplem em suas propriedades as características de condições acima a fim de reduzir a quantidade de dados mínima necessária ao estudo.

Após o período de coleta dos dados da forma explicitada anteriormente, para utilizarmos na RNA, teríamos que solucionar o problema de parametrização e modelagem dos fatores. Ou seja, transformá-los em atributos, visto que não estão disponíveis na literatura estudada os coeficientes que os representam como equação ou sua inter-relação.

Concluindo os passos anteriores, fica claro que é plausível a utilização de RNA para a determinação de cenários agronômicos. Contudo o caminho a ser trilhado depende inicialmente da coleta de dados assertiva.

4 CONSIDERAÇÕES FINAIS

Durante a pesquisa efetuada, foi possível realizar o levantamento dos principais fatores associados ao crescimento das plantas que são ambientais e de solo, com comportamento diferenciado para cada espécie vegetal.

Já quando da busca pelos coeficientes que representam os diversos fatores, esses não se encontram estimados na literatura disponível e para continuidade dos trabalhos podem ou não ser estimados, sendo que se não estimados, haverá custo maior em quantidade de dados a ser utilizada em treinamento. Ainda nesse levantamento de informações advindas da literatura ficou clara a necessidade de indicadores booleanos sobre a presença de situações atípicas para, por exemplo, temperatura, indicando se houve fuga para as zonas de estresse de temperatura, o mesmo para a pluviosidade, para excesso ou falta.

Também se conclui que os modelos provavelmente teriam a aplicação em uma ou mais microrregião geográficas, em alguns casos, em que a semelhança de clima e de solo, um mesmo modelo poderia abranger até algumas macrorregiões.

Quanto à possibilidade de determinação de cenários agronômicos com o que possuímos de bibliografia atualmente, entende-se razoável e possível a utilização de RNA para essa finalidade, além de que, o ganho para a agricultura brasileira é imensurável pela disponibilização de uma ferramenta inovadora nesse nível e porte.

REFERÊNCIAS

AVRDC. **Vegetable Production Training Manual**. Tainan: Asian Vegetable Research and Development Center, 1990. 447p.

Cotações - Soja. **Agrolink**, 2019. Disponível em: <<https://www.agrolink.com.br/cotacoes/historico/pr/soja-em-grao-sc-60kg>>. Acesso em: 10 de dez. de 2019.

FACELI, Katti, et. al. **Inteligência Artificial: Uma abordagem de Aprendizagem de Máquina**. Rio de Janeiro: LTC, 2011. 378p.

FRANCO, Cristiano Roberto. **Inteligência Artificial**. Londrina: Editora e Distribuidora Educacional S.A., 2014. 168p.

HOPKINS, Willian G. **Introduction to plant physiology**. Hoboken: Courier/Kendallville, 2008. 523p.

MEDEIROS, Luciano Frentino de. **Inteligência artificial aplicada: uma abordagem introdutória** (livro eletrônico). Curitiba: Intersaberes, 2008. 263p.

Necessidade de calagem para a cultura do café. **CaféPoint**, 2019. Disponível em: <<https://www.cafepoint.com.br/noticias/tecnicas-de-producao/necessidade-de-calagem-para-a-cultura-do-cafe-297n.aspx>>. Acesso em: 18 de dez. de 2019.

NOVAIS, Roberto Ferreira, et. al. **Fertilidade do solo**. Viçosa: Sociedade Brasileira de Ciência do Solo, 2007. 1017p.

O que é framework? **Universidade Federal de Santa Catarina**, 2019. Disponível em <<http://www.dsc.ufcg.edu.br/~jacques/cursos/map/html/frame/oque.htm>>. Acesso em: 22 de dez de 2019.

PESSARAKLI, Mohammad. **Handbook of Plant and Crop Physiology**. New York: Marcel Dekker, 2001. 973p.

RUSSEL, Stuart. **Artificial Intelligence, A modern Approach**. New Jersey: Pearson Education, Inc., 2010. 1132p.

Série Histórica - Custos - Soja - 1997 a 2019. **Conab**, 2019. Disponível em: <<https://www.conab.gov.br/index.php/info-agro/custos-de-producao/planilhas-de-custo-de-producao/item/1983-serie-historica-custos-soja-1998-2017>>. Acesso em: 10 de dez. de 2019.

SCHWAMBACH, Cornélio. **Fisiologia Vegetal: introdução às características, funcionamento e estrutura das plantas e interação com a natureza**. São Paulo: Érica, 2014. 192p.

Taxa Selic. **Banco Central do Brasil**, 2019. Disponível em: <<https://www.bcb.gov.br/controleinflacao/taxaselic>>. Acesso em: 10 de dez. de 2019.

Top 10 Best Deep Learning Frameworks in 2019. **Towards Data Science**, 2019. Disponível em <https://towardsdatascience.com/top-10-best-deep-learning-frameworks-in-2019-5ccb90ea6de>. Acesso em: 22 de dez de 2019.