

UFRRJ

**INSTITUTO DE CIÊNCIAS EXATAS
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM
MATEMÁTICA E COMPUTACIONAL**

DISSERTAÇÃO

**Utilizando uma Heurística GRASP para o Problema de Rotação de
Culturas**

Soline Maria Gonçalves Ikeda

2018



**UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE CIÊNCIAS EXATAS
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM
MATEMÁTICA E COMPUTACIONAL**

**UTILIZANDO UMA HEURÍSTICA GRASP PARA O PROBLEMA DE
ROTAÇÃO DE CULTURAS**

SOLINE MARIA GONÇALVES IKEDA

Sob Orientação do Professor
Marcelo Dib Cruz

e Co-orientação do Professor
Wagner de Souza Tassinari

Dissertação submetida como requisito parcial para obtenção do grau de **Mestre em Ciências**, no Curso de Pós-Graduação em Modelagem Matemática e Computacional, Área de Concentração em Modelagem Matemática e Computacional.


Seropédica, RJ
Julho de 2018

**INSTITUTO DE CIÊNCIAS EXATAS
CURSO DE PÓS-GRADUAÇÃO EM MODELAGEM
MATEMÁTICA E COMPUTACIONAL**

SOLINE MARIA GONÇALVES IKEDA

Dissertação submetida como requisito parcial para obtenção do grau de **Mestre em Ciências**, no Curso de Pós-Graduação em Modelagem Matemática e Computacional, área de Concentração em Modelagem Matemática e Computacional.

DISSERTAÇÃO APROVADA EM 10/07/2018



Marcelo Dib Cruz (Dr.) - UFRRJ
(Orientador)



Gizelle Kupac Vianna (Dra.) - UFRRJ



Bruno José Rodrigues Alves (Dr.) - EMBRAPA

Universidade Federal Rural do Rio de Janeiro
Biblioteca Central / Seção de Processamento Técnico

Ficha catalográfica elaborada
com os dados fornecidos pelo(a) autor(a)

I26u Ikeda, Soline Maria Gonçalves, 1993-
Utilizando uma heurística GRASP para o problema de
rotação de culturas / Soline Maria Gonçalves Ikeda. -
2018.
41 f.

Orientador: Marcelo Dib Cruz.
Coorientador: Wagner de Souza Tassinari.
Dissertação (Mestrado). -- Universidade Federal
Rural do Rio de Janeiro, Programa de Pós-graduação em
Modelagem Matemática e Computacional, 2018.

1. Rotação de culturas. 2. Heurística. 3. GRASP. I.
Cruz, Marcelo Dib, 1967-, orient. II. Tassinari,
Wagner de Souza, 1976-, coorient. III Universidade
Federal Rural do Rio de Janeiro. Programa de Pós
graduação em Modelagem Matemática e Computacional. IV.
Título.

RESUMO

IKEDA, Soline Maria Gonçalves. **Utilizando uma heurística GRASP para o problema de rotação de culturas.** 2018. 41p Dissertação (Programa de Pós-graduação em Modelagem Matemática e Computacional – PPGMMC). Instituto de Ciências Exatas. Pró-reitoria de Pesquisa e Pós-graduação, Universidade Federal Rural do Rio de Janeiro, Seropédica, RJ, 2018.

O Brasil é conhecido por seu histórico agrícola devido aos seus solos férteis, climas favoráveis à plantação e relevos propícios. Um dos focos centrais na produção vegetal, discutidos ultimamente, são medidas que visam um planejamento sustentável e ecológico, tendo em vista a degradação ambiental ocorrida nos últimos anos. A rotação de culturas é uma técnica que consiste em alternar as culturas em uma mesma área de plantio em épocas diferentes. Cada cultura possui uma determinada época em que o seu cultivo pode ser realizado e com isso, diversas culturas podem ser plantadas em um mesmo local, evitando assim o desgaste do solo. A área em que as espécies podem ser cultivadas é dividida em lotes, tal que, cada lote recebe uma cultura vegetal naquele determinado período. Cada cultura tem um valor de venda que depende da época a ser plantada e colhida. As Culturas são organizadas em famílias (devido às características comuns) e não podem ser plantadas em períodos consecutivos e em lotes adjacentes. A Rotação de Culturas tem ganhado destaque na literatura, pois é um meio de produção cujos princípios práticos viabilizam uma agricultura ecológica e produtiva. Esta prática, uma vez bem conduzida pelos agricultores rurais, traz inúmeros benefícios, tais como o controle biológico de pragas e de plantas daninhas, diminuindo a ação de pesticidas prejudiciais ao homem e ao meio ambiente e medidas de recuperação do solo, possibilitando sua maior fertilidade. O objetivo deste trabalho é propor e implementar uma heurística para simular a rotação de culturas, de tal modo que o agricultor possa planejar as culturas a serem plantadas em cada época e em cada lote ao longo do(s) ano(s), visando obter o lucro máximo. A heurística proposta utiliza *meta-heurística Greedy Randomized Adaptive Search Procedures* (GRASP). É um método iterativo que possui duas fases. A primeira fase gera uma solução inicial e a partir desta, na segunda fase, são realizadas buscas locais com o objetivo de melhorar a solução encontrada. No final, o método proposto é comparado com outros métodos encontrados na literatura. Os resultados obtidos neste estudo podem auxiliar os agricultores a aproveitarem melhor o seu solo, área de plantio, evitando o desgaste do mesmo, realizando a produção de uma variedade maior de culturas, aumentando sua produção e renda.

Palavras-chave: Rotação de culturas, Heurística, GRASP.

ABSTRACT

IKEDA, Soline Maria Gonçalves. **Using a GRASP heuristic for the problem of crop rotation.** 2018. 41p Dissertation (Postgraduate Program in Mathematics and Computational Modeling). Institute of Exact Sciences. Pro-rector of Research and Post-graduation, Federal Rural University of Rio de Janeiro, Seropédica, RJ, 2018.

One of the central focuses in plant production, discussed lately, is measures aimed at sustainable and ecological planning. Crop rotation is an advantageous technique of varying crops in the same planting area at different times. Each culture has a certain time when its cultivation can be realized and using this method of rotation, several crops can be planted in one place. This practice has many benefits, since the control of pests and weeds is carried out biologically, reducing the action of harmful pesticides to the environment and soil recovery measures. The planning of the crops to be planted is a complex, combinatorial and difficult problem, due to the set of constraints. The objective of this work is to propose and implement a heuristic to simulate the rotation of crops, so that the farmer can plan the crops to be planted at each time and in each lot during the year(s). For this, a heuristic was constructed using Greedy Randomized Adaptive Search Procedures (GRASP) metaheuristics. It is an iterative method that has two phases. The first phase generates an initial solution and from this, in the second phase, local searches are carried out in order to improve the solution found. The results obtained in this study can help farmers to make better use of their soil, planting area, avoiding crop wear, producing a larger variety of crops, increasing their production and income.

Key words: Crop rotation, Heuristic, GRASP.

LISTA DE TABELAS

Tabela 1: Exemplo rotação de culturas.	1
Tabela 2: Exemplo rotação de culturas com as restrições.	5
Tabela 3: Configuração dos lotes.	5
Tabela 4: Informações dos parâmetros aplicados ao HGARC.	14
Tabela 5: Informações das culturas.	14
Tabela 6: Tamanho dos lotes (hectare).	15
Tabela 7: Tamanho dos lotes reais para matriz com 16 lotes (hectare).	15
Tabela 8: Lucratividade mensal das culturas por metro quadrado (R\$).	16
Tabela 9: Resultados com solução inicial e melhor solução após a busca local aplicando o HGARC.	17
Tabela 10: Resultados com solução inicial e após a busca local aplicando o HGARC.	17
Tabela 11: Comparação dos resultados de FILHO (2012) com o HGARC.	18
Tabela 12: Informações dos parâmetros aplicados o HGARC.	23
Tabela 13: Informações das culturas com suas respectivas lucratividades fixas.	24
Tabela 14: Resultados com melhores soluções para restrição de adjacências em doze meses aplicando o HGARC.	24
Tabela 15: Resultados com as melhores soluções para solução inicial e após aplicar a busca local na mesma aplicando o HGARC.	25
Tabela 16: Comparação dos resultados do HGARC com a literatura.	25

LISTA DE FIGURAS

Figura 1: Pseudocódigo do procedimento GRASP.....	8
Figura 2: Pseudocódigo da fase construtiva.	9
Figura 3: Pseudocódigo da fase de busca local.	9
Figura 4: Representação da solução gerada pelo HGARC.....	10
Figura 5: Pseudocódigo da Lista Restrita de Candidatos aplicada ao HGARC.	11
Figura 6: Pseudocódigo da fase construtiva aplicada ao HGARC.	11
Figura 7: Pseudocódigo da fase de busca local aplicada ao HGARC.	12
Figura 8: Pseudocódigo do procedimento HGARC para o problema da rotação de culturas.	13
Figura 9: Configurações para 10, 15 e 20 lotes.	16
Figura 10: Configuração para 16 lotes.	17
Figura 11: Matriz com 10 Lotes e 12 meses. Lucratividade: R\$1.276.000,00.....	18
Figura 12: Matriz com 15 Lotes e 12 meses. Lucratividade: R\$ 1.826.000,00.....	18
Figura 13: Matriz com 20 Lotes e 12 meses. Lucratividade: R\$ 2.420.000,00.....	19
Figura 14: Matriz com 16 Lotes e 24 meses. Lucratividade: R\$ 5.055.700,00.....	20
Figura 15: Matriz com 16 Lotes e 36 meses. Lucratividade: R\$ 5.808.000,00.....	21
Figura 16: Melhor configuração para o Algoritmo Genético.	22
Figura 17: Melhor configuração para o <i>Simulated Annealing</i>	22
Figura 18: Melhor configuração para o <i>Simulated Annealing</i> com Algoritmo Genético.....	22
Figura 19: Melhor configuração para o Memético.....	23
Figura 20: Resultado com restrição de adjacências para 10 lotes em 12 meses.....	26
Figura 21: Resultado com restrição de adjacências para 15 lotes em 12 meses.....	26
Figura 22: Resultado com restrição de adjacências para 20 lotes em 12 meses.....	27
Figura 23: Resultado com restrição de adjacências para 10 em períodos não adjacentes.....	27
Figura 24: Resultado com restrição de adjacências para 15 lotes em períodos não adjacentes.	28
Figura 25: Resultado com restrição de adjacências para 20 lotes em períodos não adjacentes.	28
Figura 26: Melhor programação para 10 lotes em períodos não adjacentes..	28
Figura 27: Melhor programação para 15 lotes em períodos não adjacentes.	29
Figura 28: Melhor programação para 20 lotes em períodos não adjacentes.	29

SUMÁRIO

1 INTRODUÇÃO	1
2 DESCRIÇÃO DO PROBLEMA	4
3 REVISÃO DA LITERATURA	6
4 MATERIAIS E MÉTODOS	7
4.1 META-HEURÍSTICA GRASP APLICADA AO PROBLEMA DA ROTAÇÃO DE CULTURAS	10
4.1.1 CONSTRUTIVO	11
4.1.2 BUSCA LOCAL.....	12
5. RESULTADOS.....	14
6 CONCLUSÃO.....	30
7 REFERÊNCIAS BIBLIOGRÁFICAS	31

1 INTRODUÇÃO

O Brasil ocupa um lugar de destaque no cenário agrícola mundial, sendo um dos maiores produtores e exportadores na agropecuária mundial. Além de cumprir com sua função de produção de alimentos para abastecer o mercado interno, a agricultura tem exercido papel fundamental para o equilíbrio da balança comercial brasileira (FRANCHINI; COSTA; DEBIASI; *et. al.*; 2011). Desde o Brasil colonial, a produção agrícola convencional se baseia principalmente na monocultura, motivada pelo baixo custo operacional e facilidade de implementação. Mas isto acarreta uma série de prejuízos, tais como o uso maciço de capitais e pesticidas tóxicos, que por sua vez, são altamente prejudiciais ao meio ambiente, facilitando a ação e prevalência de pragas e patógenos (FILHO; 2012). Com este uso crescente de agrotóxicos, regulamentações que restringem o uso dos mesmos estão sendo criadas e esse fator incentivou os agricultores a procurarem medidas sustentáveis como alternativa ao plantio tradicional.

A agricultura ecológica se baseia em estratégias de diversificação, tais como policulturas, rotações, cultivos de cobertura e integração animal, para melhorar a produtividade, e garantir a saúde do agroecossistema (PENTEADO; 2012). Observou-se que a biodiversidade permite a manutenção da cadeia alimentar, de forma a propiciar o equilíbrio das espécies, pois quanto mais estabilizado estiver o ecossistema local, menores serão os problemas fitossanitários. Quanto maior a população de inimigos naturais, menor será o ataque de pragas nas culturas existentes ao redor. Consequentemente, se ocorrerem mudanças no sistema agrícola atual, a aplicação dos insumos químicos será cada vez menos necessária (MARIANI & HANKS *apud* GLIESSMAN, 2009). No entanto, dois problemas ecológicos afetam a agricultura moderna de forma considerável: a erosão do solo, causada pelo manejo excessivo, e a incidência de doenças nas culturas, decorrente da monocultura praticada indiscriminadamente. (SANTOS; REIS; 2001).

Dessa forma, começou a ser utilizado e recomendado aos agricultores os usos do sistema de Rotação de Culturas. Porém estes ainda têm dificuldade em aceitar a implantação deste tipo de plantio devido às incertezas com relação aos ganhos financeiros, épocas de plantio, clima, entre outros.

A rotação de culturas consiste em alternar, anualmente, espécies vegetais, numa mesma área agrícola como ilustra um exemplo na tabela 1.

Tabela 1: Exemplo rotação de culturas.

	Mês 1	Mês 2	Mês 3
Área 1	Cultura 1	Cultura 2	Cultura 3
Área 2	Cultura 3	Cultura 4	Cultura 1

Fonte: elaborado pela autora.

No exemplo acima, desenvolvido apenas para auxiliar no entendimento do funcionamento da rotação de culturas, existem quatro tipos de culturas a serem plantadas em duas áreas durante 3 meses. Cada cultura necessita de um mês para completar seu ciclo. É possível ver que as culturas se alternam nos meses e nas áreas de plantio. Em suma, é isto que acontece nesse tipo de processo de plantação.

As vantagens da rotação de culturas são inúmeras. Além de proporcionar a produção

diversificada de alimentos e outros produtos agrícolas, se adotada e conduzida de modo, essa prática melhora as características físicas, químicas e biológicas do solo, auxilia no controle de plantas daninhas, doenças e pragas. Repõe matéria orgânica e protege o solo da ação dos agentes climáticos (EMBRAPA SOJA; 2003). É importante destacar que a manutenção e melhoria do desempenho econômico e social do agronegócio passam, necessariamente, pelo desenvolvimento e adoção de tecnologias capazes de manter e incrementar o potencial produtivo do solo, de modo a aumentar a produtividade e racionalizar a utilização dos insumos necessários à produção agropecuária. Ao mesmo tempo, essas tecnologias devem contribuir para a promoção de uma agricultura ambientalmente sustentável, aspecto que vem sendo cada vez mais cobrado pela sociedade (FRANCHINI; COSTA; DEBIASI; *et. al.*; 2011).

Dentre os fatores do pouco uso da rotação de culturas pelos agricultores é que o retorno é medido em anos devido a rotação obedecer ao ciclo anual de plantio. Por isso é necessário ter uma visão de negócio em longo prazo, pois o retorno trará lucros ao produtor não somente na colheita e venda dos produtos, mas também na economia dos insumos utilizados na monocultura.

O planejamento das culturas a serem plantadas é um problema complexo, combinatório e de difícil solução, devido ao conjunto de restrições. No problema uma certa quantia de lotes (definida pelo agricultor) é reservada para que possa ser aplicada a rotação de culturas. Tal que nesses lotes serão cultivadas as culturas disponíveis conforme o programado. A grande complexidade está em alocar cada cultura em um lote diferente e seguir todas as restrições impostas, pois quando maior o número de dados e maior o número de restrições, mais difícil é encontrar uma solução factível. Uma maneira de resolver este problema é através da Pesquisa Operacional (PO) e heurísticas. A Pesquisa Operacional (Definição segundo a SOBRAPPO – Sociedade Brasileira de Pesquisa Operacional) é uma ciência aplicada voltada para a resolução de problemas reais. Tem como foco a tomada de decisões, aplicando conceitos e métodos de várias áreas científicas na concepção, planejamento ou operação de sistemas. Foi desenvolvida então a ideia de criar modelos matemáticos, apoiados em dados e fatos, que permitissem perceber os problemas em estudo e simular e avaliar o resultado hipotético de estratégias ou decisões alternativas. Dentro da PO são definidas as heurísticas.

Segundo Diaz & Glover, *et al* (1996) heurística pode ser um algoritmo capaz de alcançar soluções próximas do real para um problema específico, por meio de uma função objetivo. Métodos heurísticos tem o objetivo de encontrar as melhores soluções em tempos computacionais acessíveis, no meio de uma coleção de elementos discretos. Um problema de otimização combinatória compreende a relação das variáveis de decisão com a uma função objetivo e um conjunto de restrições. Uma função objetivo pode obter valores mínimos ou máximos dentro do espaço de busca delineado para o problema (RUSSELL; NORVIG, 2004).

O objetivo deste trabalho é propor e implementar uma heurística para simular a rotação de cultura, de tal modo que o agricultor possa planejar as culturas a serem plantadas em cada época e em cada lote ao longo do(s) ano(s). Para obter uma solução, foi construída uma heurística utilizando a meta-heurística *Greedy Randomized Adaptive Search Procedures* (GRASP). É um método iterativo que possui duas fases. A primeira fase gera uma solução inicial e a partir desta, na segunda fase, são realizadas buscas locais com o objetivo de melhorar a solução encontrada.

No final o método proposto é testado com outros métodos encontrados na literatura. Esses tratam de modelos de otimização para encontrar resultados para o problema de rotação de culturas. Dentre os trabalhos (capítulo 3) tem o modelo que utiliza o *Clustering Search* (ARAÚJO & MAURI, 2012) levando-se em consideração as mesmas restrições utilizadas neste trabalho. Enquanto o segundo faz o uso de diferentes meta-heurísticas a fim de obter comparações como *Simulated Annealing* e Algoritmo Genético (FILHO, 2012). Os resultados

obtidos neste estudo podem auxiliar os agricultores a aproveitarem melhor o seu solo, área de plantio, evitando o desgaste do mesmo, realizando a produção de uma variedade maior de culturas, aumentando sua produção e renda.

2 DESCRIÇÃO DO PROBLEMA

Para obter-se um bom resultado ao aplicar o método de plantio rotação de culturas, é necessário seguir algumas restrições. Abaixo estão as restrições que foram implementadas neste trabalho afim de que o agricultor possa ter o melhor retorno possível seguindo alguns princípios:

1. Obedecer aos ciclos e períodos de plantio de cada cultura;
2. Não plantar culturas de mesma família em lotes adjacentes;
3. Culturas de uma mesma família botânica não podem ser plantadas consecutivamente em um mesmo lote;
4. Ter pelo menos um período de descanso do solo (pousio) em cada lote durante o período de plantio;
5. Ter pelo menos uma adubação verde, que é feita através do plantio das leguminosas presentes, durante o período de plantio;

Os ciclos e períodos de plantio de cada cultura devem ser obedecidos devido à sua adaptação a cada época. Por exemplo, existem plantas que gostam mais de Sol enquanto outras preferem sombra e dependendo da estação ou época do ano é possível ter mais ou menos luz Solar. As famílias de culturas são grupos de culturas que possuem características em comum como folhagem, raízes, dentre outras. No item 2 e 3, a restrição se refere a proibição do plantio de culturas de mesma família em lotes adjacentes devido, dentre outros problemas, a infestação de pragas que podem se proliferar em culturas de mesma família. Ao evitar esse plantio, também são evitadas as pragas que afetam essas plantas, pois, o ciclo de reprodução delas é quebrado. O período de pousio (item 4) é importante para o solo, pois, é um período de descanso do mesmo em que ocorre sua recuperação da estrutura e fauna. No item 5 é indicado o uso de leguminosas entre os ciclos da plantação. É possível ver essa importante etapa da rotação de culturas em diversas literaturas que tratam de ecologia na agricultura devido as inúmeras vantagens que elas trazem ao solo. Dentre essas vantagens, estão (PAULA, 2017):

- A melhora das propriedades físicas e orgânicas do solo, uma vez que a matéria orgânica das plantas depositada ao solo enriquece e auxilia a estrutura do solo;
- Traz para a superfície do solo, os nutrientes minerais do subsolo, pois suas raízes profundas conseguem extrair os nutrientes que se encontram abaixo da camada normalmente utilizada pelas plantas;
- Introduz Nitrogênio no solo, pela fixação biológica, reduzindo gastos com fertilizantes nitrogenados;
- Promove a retenção de umidade do solo, devido a cobertura morta das plantas depositadas no solo, impedirem que a água evapore pela ação das altas temperaturas, dentre muitos outros benefícios.

Para exemplificar melhor como ocorre a rotação de culturas de acordo com as restrições descritas, foi desenvolvida a Tabela 2.

Tabela 2: Exemplo rotação de culturas com as restrições.

	Janeiro	Fevereiro	Março	Abril	Maio
Área 1	Ervilha	Ervilha	Pousio	Alface	Alface
Área 2	Pousio	Beterraba	Beterraba	Feijão	Feijão
Área 3	Feijão	Feijão	Alface	Alface	Pousio

Fonte: elaborado pela autora.

Como dito nas restrições, em todo lote (área) deve haver um período de pousio, ademais, também deve haver pelo menos uma leguminosa para renovar o oxigênio do solo. E culturas de mesma família não devem ficar em lotes adjacentes ao mesmo tempo. Visto isto, as culturas 1 e 2 são da mesma família, sendo a 3 de família diferente. As Leguminosas 1 e 2 são de mesma família. Deve ser levado em conta que em cada cultura, leguminosa e pousio os períodos de plantio foram respeitados. Foi ilustrada uma simples exemplificação do que seria uma rotação de culturas na realidade.

Para a configuração dos lotes, a fim de não haver plantio de famílias iguais uma ao lado da outra, segue a tabela 3.

Tabela 3: Configuração dos lotes.

Área 1	Área 2	Área 3
--------	--------	--------

Fonte: elaborado pela autora.

Pode-se imaginar que estas três áreas estão em uma mesma fazenda e são particionadas em sequência. Assim, a área 1 é adjacente à 2 e esta é adjacente à 3.

3 REVISÃO DA LITERATURA

A partir de pesquisas realizadas na literatura, foram encontrados diversos trabalhos que abordam o assunto do problema na rotação de culturas. O trabalho de (SANTOS, 2007), intitulado de “Um modelo para a programação de rotação de culturas” trata de um modelo de otimização 0-1 para determinar a logística da rotação de culturas em uma área dividida por lotes. O objetivo do trabalho é maximizar a ocupação das áreas de plantio. As restrições do modelo de Santos (2007) são as mesmas utilizadas neste trabalho.

Outra pesquisa encontrada na literatura foi a de (GOMES, 2011), intitulada “Otimização linear aplicada ao plantio sustentável de vegetais”. O objetivo do autor é auxiliar associações do Rio de Janeiro e São Paulo a organizar o que, quando e quanto cada agricultor (pequeno e médio porte) associado deverá plantar, ou seja, estabelecer um padrão e organização ao cultivo das hortaliças. Deve-se maximizar o lucro e minimizar o total de lotes utilizados, pois, uma distribuição vasta de lotes torna a administração dos mesmos inaceitável na prática. Isso foi possível através das modelagens matemáticas e métodos desenvolvidos no trabalho do autor. Gomes cita ainda que com esse maior planejamento adequado é possível garantir o atendimento da demanda exigida com o melhor aproveitamento da terra, produzindo alimentos com redução no uso de fertilizantes e afins, aumentando a qualidade da produção. Como a demanda é um dos fatores principais da pesquisa, essa deve ser incluída nas restrições.

Como o resultado será aplicado a pequenos e médios agricultores, existe a possibilidade de existirem lotes demasiado pequenos. Tendo em vista isso, também foi inserida uma restrição para o tamanho mínimo do lote a ser usado na rotação. Dois modelos heurísticos foram utilizados para gerar as soluções, o GC-BC: Geração de Colunas – *Branch and Cut* e a Heurística do Lote Fixo. O primeiro modelo visa a geração de colunas para adicionar variáveis binárias e restrições para cada coluna gerada. Enquanto o segundo modelo fixa o valor de algumas variáveis no tamanho mínimo desejado para um lote. Foram utilizados dados de 23 culturas. Gomes ilustra ainda os resultados obtidos levando-se em conta o número de áreas que serão divididas em lotes menores e os lucros obtidos ao aumentar ou diminuir o número dessas áreas para o algoritmo GC-BC.

Um terceiro trabalho que trata do mesmo assunto utilizando heurísticas é o de (ARAÚJO, 2013), intitulado “*Clustering Search* Para Resolução De Um Problema De Rotação De Culturas Com Restrições De Adjacências”. O objetivo é aplicar a meta-heurística *Clustering Search* (CS) que considera um conjunto de restrições de adjacências utilizando o *Simulated Annealing* (SA) como gerador de soluções ao longo do processo de busca.

Por fim, o trabalho de (FILHO, 2012), intitulado “Meta-heurística em um problema de rotação de culturas”, foi desenvolvido a fim de encontrar melhores resultados em termos de lucratividade para uma plantação que utiliza a rotação de culturas como método de plantio. Nele, o autor utiliza várias meta-heurísticas para realizar comparações e encontrar o melhor resultado. Foram utilizados 10, 15, 16 e 20 lotes nos experimentos, além de uma gama de 30 culturas em um período de 12 e 24 meses.

4 MATERIAIS E MÉTODOS

Antes de introduzir de fato o método utilizado para encontrar os resultados deste trabalho, é necessário falar sobre alguns conceitos. Primeiramente, antes de definir o que é meta-heurística, é importante conceituar a Pesquisa Operacional e otimização. A Pesquisa Operacional (Definição segundo a SOBRAPO – Sociedade Brasileira de Pesquisa Operacional) é uma ciência aplicada voltada para a resolução de problemas reais. Tendo como foco a tomada de decisões, aplica conceitos e métodos de várias áreas científicas na concepção, planejamento ou operação de sistemas. A Pesquisa Operacional surgiu durante a Segunda Guerra Mundial, da necessidade de lidar com problemas de natureza logística, tática e de estratégia militar de grande dimensão e complexidade. Para apoiar os comandos operacionais na resolução desses problemas, foram então criados grupos multidisciplinares de matemáticos, físicos e engenheiros e cientistas sociais. Esses cientistas não fizeram mais do que aplicar o método científico, que tão bem conheciam, aos problemas que lhes foram sendo colocados. Desenvolveram então a ideia de criar modelos matemáticos, apoiados em dados e fatos, que lhes permitissem perceber os problemas em estudo e simular e avaliar o resultado hipotético de estratégias ou decisões alternativas. A otimização é uma área afim da Pesquisa Operacional. A otimização se refere a escolher o melhor elemento em um conjunto de alternativas disponíveis, de modo a otimizar, melhorar um ou mais objetivos pré-estabelecidos como, minimizar custos ou riscos, maximizar lucros ou confiabilidade sob determinadas restrições. Desenvolvem-se métodos exatos e métodos aproximados para a solução de tais problemas. Atualmente, a área de otimização é composta por diversos campos, porém há algumas intersecções entre seus subcampos. Algumas subáreas são:

- Programação Linear: a função objetivo é linear e há um conjunto de restrições relacionadas às variáveis da função, que são especificadas como igualdades ou desigualdades lineares;
- Programação Inteira: apresenta problemas geralmente mais complexos que os de programação linear, com variáveis que se restringem a valores inteiros;
- Otimização Combinatória: o conjunto de soluções factíveis é ou pode ser reduzido a um conjunto discreto;
- Otimização Estocástica: estuda os casos em que as restrições ou os parâmetros dependem de variáveis aleatórias.

Um algoritmo é considerado um método heurístico quando não há conhecimentos matemáticos completos sobre seu comportamento, ou seja, quando, sem oferecer garantias, o algoritmo objetiva resolver problemas complexos utilizando uma quantidade não muito grande de recursos - especialmente no que diz respeito ao consumo de tempo - para encontrar soluções de boa qualidade. Uma meta-heurística é um conjunto de conceitos que pode ser utilizado para definir métodos heurísticos aplicáveis a um extenso conjunto de diferentes problemas. Em outras palavras, uma meta-heurística pode ser vista como uma estrutura algorítmica geral que pode ser aplicada a diferentes problemas de otimização com relativamente poucas modificações que possam adaptá-la a um problema específico (GLOVER; KOCHENBERGER, 2009). Existem diversas meta-heurísticas e entre elas estão:

- *Simulated annealing*: É um método de busca local que permite movimentos que não são

de melhora. Isto é feito simulando o processo físico de recozimento (annealing). No recozimento, substâncias físicas como metais são fundidos a alta temperatura e depois resfriados lentamente até atingir o estado sólido;

- *Greedy Randomized Adaptive Search Procedures* (GRASP): É um processo iterativo do tipo multistart para obter soluções para problemas de Otimização combinatória. É um método que consiste de duas fases: uma de construção e outra de busca local. A primeira fase constrói uma solução viável para o problema proposto. A busca local tenta melhorar a solução obtida na fase anterior.
- *Variable Neighborhood Search* (VNS): Aplicar busca local amostrando vizinhos da solução corrente. Quando não for possível encontrar uma solução vizinha melhor, utiliza-se uma vizinhança diferente ou maior.
- *Variable Neighborhood Descent* (VND): Ainda Segundo Lacerda, a VND consiste em aplicar a mudança de vizinhanças durante a busca local.
- Busca tabu ou *Tabu Search*: A *Tabu Search* mantém uma lista de soluções candidatas visitadas recentemente (Lista Tabu) e se recusa a revisitar estas candidatas até que um determinado tempo se passe. Quando um máximo (mínimo) é encontrado, força-se uma busca para um ponto distante do corrente, pois não é permitida a permanência ou retorno para o máximo (mínimo). Isto faz com que uma área mais abrangente do espaço de soluções seja visitada;
- Algoritmos genéticos: É originário da analogia entre a representação de uma complexa estrutura por meio de um vetor de componentes, constituindo um cromossomo artificial. No processo de seleção das espécies vivas, a descendência procura preservar e levar para as próximas gerações aquelas que têm características mais desejáveis - determinadas e levadas as gerações subsequentes pela combinação dos cromossomos pais;
- Colônias de formigas: Simulação do comportamento de um conjunto de agentes que cooperam para resolver um problema de otimização através de comunicações simples.

O GRASP, proposto por (FEO; RESENDE, 1995) é um método iterativo e guloso (prefere os elementos que tragam maior benefício ao modelo) que possui duas fases. A primeira fase gera uma solução inicial e a partir desta, na segunda fase, são realizadas buscas locais com o objetivo de melhorar a solução encontrada. O critério de parada usado em muitos casos é o número máximo de iterações. A melhor solução obtida ao final da execução do GRASP é a solução final encontrada para o problema. A Figura 1 ilustra um pseudocódigo para o GRASP.

1.	Método GRASP (Max_iteracoes)
2.	Carrega dados do problema
3.	Para k= 1 até Max_iteracoes Faça
4.	Solução = construtivo()
5.	solucaoBuscaLocal = buscaLocal(solucao)
6.	Fim Para
7.	Retorna (solucao_BuscaLocal)
8.	Fim GRASP

Figura 1: Pseudocódigo do procedimento GRASP.

O GRASP é uma meta-heurística constituída por heurísticas construtivas e busca local. Consiste de múltiplas aplicações de busca local, cada uma iniciando de uma solução diferente. As soluções iniciais são geradas por algum tipo de construção randômica gulosa ou algum esquema de perturbação. A Figura acima apresenta o algoritmo básico do GRASP. Observa-se

no algoritmo que há duas fases: construção da solução e aplicação da busca local na solução construída. Além disso, o algoritmo armazena a melhor ou as melhores soluções encontradas (FREDDO; BRITO, 2008). Na figura 2 a seguir é descrito o pseudocódigo da fase de construção.

1.	Solução = $\emptyset$
2.	Método construtivo()
3.	Constrói uma lista restrita de candidatos (LRC)
4.	Enquanto (solução não estiver completa) Faça
5.	Seleciona aleatoriamente um elemento s da LRC
6.	solução = solução $\cup$ s
7.	Fim Enquanto
8.	Retorna (solução)
9.	Fim construtivo()

Figura 2: Pseudocódigo da fase construtiva.

Nesta fase de construção, produz-se uma solução factível, de forma iterativa (os elementos da solução são escolhidos um a um). A cada iteração de construção, a escolha do próximo elemento a ser adicionado à solução é determinada pela ordenação de todos os elementos candidatos, com base em uma função. Esta função recebe como entrada a lista restrita de candidatos (LRC) e verifica quais são os benefícios de se escolher cada um. Pode-se afirmar, então, que se trata de uma heurística adaptativa, já que os benefícios associados aos elementos são atualizados a cada iteração de construção, para que sempre se leve em consideração a última escolha realizada (LUZIA; RODRIGUES, 2010).

Através de um fator α (alfa) é criada uma lista restrita de candidatos LRC. O valor de α influencia na qualidade e diversidade da solução gerada na fase de construção. Valores baixos para α geram soluções gulosas de boa qualidade, pois correspondem a escolha de uma gama menor de elementos disponíveis, porém tem pouca diversidade. Um valor alto para α , leva a uma grande diversidade, devido ao fato de haverem mais elementos disponíveis para escolha, com soluções de qualidade inferior. Isso também influencia o processo de busca local, pois soluções de qualidade inferior tornam o processo de busca local mais lento.

No pseudocódigo a seguir (Figura 3) está contida a segunda fase do GRASP ou fase de busca local consiste em refinar a solução encontrada na primeira fase aplicando um método de busca local. Isso corresponde a uma intensificação na solução encontrada explorando regiões vizinhas através da busca local para encontrar um ótimo local. A busca local pode ser sofisticada, entretanto não se deve esquecer do diferencial do GRASP que é amostrar o espaço com gerações rápidas. Quanto melhor for a qualidade da solução gerada na primeira fase, maior será a velocidade para encontrar um ótimo local pela fase de busca local (FREDDO; BRITO, 2008).

1.	Método buscaLocal (solução)
2.	Enquanto (condição de parada não for satisfeita) Faça
3.	Escolha aleatoriamente um elemento x
4.	Se somaTotal(solução $\cup$ x) > somaTotal(solução) Então
5.	solução = solução $\cup$ x
6.	Fim se
7.	Fim Enquanto
8.	Retorna (solução)
9.	Fim buscaLocal()

Figura 3: Pseudocódigo da fase de busca local.

4.1 META-HEURÍSTICA GRASP APLICADA AO PROBLEMA DA ROTAÇÃO DE CULTURAS (HGARC)

O algoritmo foi desenvolvido na linguagem Java utilizando o software gratuito NetBeans IDE, versão 8.0.2 em um computador Core i7, com 6GB de memória RAM e 1TB de memória de disco rígido. Foram realizadas 200 iterações para cada execução do algoritmo, além do α aleatório. Para verificar a qualidade dos algoritmos, foram utilizadas duas abordagens do problema encontradas na literatura.

O problema da rotação de culturas pode ser representado em tabelas ou matrizes. Como pode ser visto na Figura 4, as colunas da matriz representam os meses do ano, no caso, como são 12 colunas, o intervalo de plantio vai de janeiro a dezembro. As linhas da matriz representam os lotes que o local de plantio possui e neste exemplo são dispostos 10 lotes para realizar a rotação das culturas. Cada elemento na matriz representa uma cultura (tabela 5).

	1	2	3	4	5	6	7	8	9	10	11	12
1	1.0	1.0	30.0	9.0	9.0	9.0	9.0	30.0	28.0	28.0	28.0	30.0
2	30.0	30.0	29.0	29.0	29.0	29.0	30.0	30.0	2.0	2.0	2.0	2.0
3	30.0	30.0	2.0	2.0	2.0	2.0	7.0	7.0	27.0	27.0	27.0	30.0
4	23.0	23.0	23.0	23.0	8.0	8.0	1.0	1.0	30.0	1.0	1.0	30.0
5	16.0	16.0	16.0	30.0	30.0	3.0	3.0	3.0	26.0	26.0	26.0	30.0
6	23.0	23.0	23.0	23.0	30.0	18.0	18.0	18.0	18.0	18.0	1.0	1.0
7	30.0	30.0	2.0	2.0	2.0	2.0	8.0	8.0	26.0	26.0	26.0	30.0
8	23.0	23.0	23.0	23.0	7.0	7.0	30.0	18.0	18.0	18.0	18.0	18.0
9	19.0	19.0	19.0	19.0	19.0	30.0	7.0	7.0	26.0	26.0	26.0	30.0
10	1.0	1.0	30.0	30.0	23.0	23.0	23.0	23.0	11.0	11.0	11.0	11.0

Figura 4: Representação da solução gerada pelo HGARC.

Existem diversos estudos sobre métodos heurísticos aplicados à rotação de culturas a fim de aumentar a lucratividade, utilizar menos insumos, aproveitar melhor o campo de plantio entre outras vantagens. Neste trabalho, foi utilizada a meta-heurística GRASP objetivando aumentar o lucro retornado ao final de um período predeterminado de plantio. Esta meta-heurística foi escolhida, pois dentre inúmeras vantagens:

- Gera uma solução inicial para que a partir dela possam ser geradas outras soluções;
- Para melhorar a solução faz a avaliação dos elementos disponíveis para verificar se estes melhorarão a solução;
- Objetiva inserir na solução sempre os melhores elementos possíveis, ou seja, que melhore ao máximo a solução;
- Ao final de cada busca local têm-se então uma solução melhor ou igual a encontrada anteriormente.

Como o problema aqui tratado possui muitas restrições, gerar alguma solução viável é um processo complexo. O GRASP permite que a cada iteração, seja gerada uma solução inicial diferente, que depois é refinada pela busca local. Com isso, é possível diversificar bem o espaço de busca.

4.1.1 CONSTRUTIVO

Para encontrar a solução inicial o algoritmo executa o método que retorna a Lista Restrita de Candidatos. Para este trabalho a LRC ordena as culturas em ordem decrescente da razão lucro por ciclo, ou seja, o valor total de retorno de cada cultura é dividido pelo número de meses para que ela complete um ciclo. Supondo que a alface tem lucro fixo de 300 reais para todo o ciclo que dura dois meses, o resultado seria $300/2$ que seria igual a 150 reais mensais de lucro. O almeirão tem um lucro fixo de 150 reais para todo o ciclo que dura quatro meses, o resultado seria $150/4$ que seria igual a 37,5 reais mensais de lucro. Observando esse exemplo, na LRC o almeirão ficaria localizado abaixo da alface. O método foi desenvolvido como abaixo na Figura 5.

```
1.  Método Constrói_LRC ()
2.      Para i = 1 até numCulturas Faça
3.          lucroCultura(i) = lucroTotalCultura(i)/ numeroCiclo(i)
4.          Atualiza LRC
5.      Fim para
6.      Ordenar as culturas
7.  Retorna LRC
```

Figura 5: Pseudocódigo da Lista Restrita de Candidatos aplicada ao HGARC.

A solução inicial é gerada a partir da LRC, pois as culturas que serão escolhidas para compor a solução estão contidas na LRC. A princípio a LRC é ordenada inicialmente como descrito anteriormente, em ordem decrescente de lucro mensal. Depois é escolhido o α (valores entre 0 e 1) aleatório, de forma que a cada nova iteração uma nova LRC é gerada. Esta escolha aleatória é feita para que a gama de culturas escolhidas possa ser diversificada, dessa forma em alguns casos a LRC é maior e em outros menor e com isso é evitado ao algoritmo ficar parado em um ótimo local. Também é escolhida aleatoriamente a fim de tornar as soluções mais diversificadas. Em cada iteração, as culturas são escolhidas de forma aleatória. A solução é construída em cada linha da matriz, sempre respeitando as restrições do problema. O algoritmo está descrito na Figura 6.

```
1.  Solução =  $\emptyset$ 
2.  Constrói uma lista restrita de candidatos (LRC)
3.   $\alpha$  é determinado aleatoriamente
4.   $LRC = \alpha * LRC$ 
5.  Método construtivo()
6.      Enquanto (todas as posições da matriz não estiverem ocupadas) Faça
7.          Para cada i = 1 até número de linhas (lotes) da matriz Faça
8.              Se s satisfaz as restrições da LRC
9.                   $S(i) = S(i) \cup s$ 
10.         Fim Enquanto
11.     Retorna (solução)
12. Fim construtivo()
```

Figura 6: Pseudocódigo da fase construtiva aplicada ao HGARC.

4.1.2 BUSCA LOCAL

Após a fase de construção tem-se a fase de busca local onde os resultados encontrados na solução inicial tentam ser melhorados. Para que a solução possa ser modificada, primeiramente é selecionada aleatoriamente uma posição da matriz solução para ser modificada. Após escolhida a posição é selecionada uma cultura usando a LRC ordenada. Para as 50 primeiras iterações é usado o método da LRC ordenada em ordem decrescente segundo a lucratividade mensal de cada cultura, após estas iterações é usado, então, o método do α aleatório para cada 50 iterações até completar 200. Então essa cultura é testada e se estiver conforme todas as restrições impostas, ela é inserida na matriz solução. Ao final de todas as iterações a matriz terá um novo lucro total que poderá ser melhor ou não que o anterior. Dessa forma para saber se um resultado encontrado na busca local é realmente melhor que o anterior, uma comparação com o valor do lucro total da solução inicial é feita. Se o valor for maior, então esse resultado é armazenado como uma possível melhor solução encontrada para o problema. O algoritmo para a fase da busca local pode ser visto na Figura 7 a seguir.

1.	Constrói uma lista restrita de candidatos (LRC)
2.	Método buscaLocal (solução)
3.	Se (numIterações é menor que 50) Então
4.	LRC = LRC em ordem decrescente
5.	Senão
6.	α é determinado aleatoriamente
7.	Enquanto (numIterações não for o máximo escolhido) Faça
8.	Escolha aleatoriamente um elemento x da LRC
9.	Se somaTotal(solução U x) > somaTotal(solução) Então
10.	solução = solução U x
11.	Fim se
12.	Fim Enquanto
13.	Retorna solução
14.	Fim buscaLocal()

Figura 7: Pseudocódigo da fase de busca local aplicada ao HGARC.

A Figura 8 ilustra um pseudocódigo para o HGARC aplicado ao problema da rotação de culturas. Primeiramente ocorre a leitura dos dados do problema e em seguida ocorrem as iterações para encontrar a solução do problema. Dentro da fase de construção também ocorrem iterações para que as culturas sejam alocadas na matriz solução, pois é preciso realizar testes para ver se a cultura escolhida atende às restrições impostas. Se não estiverem de acordo com as restrições, então, outra cultura deve ser escolhida. Ao terminar a fase de construção é iniciada a fase da busca local onde o resultado encontrado sofre modificações a fim de que este retorne na solução final um valor melhor do que o encontrado. Ao encontrar uma solução melhor, esta é armazenada e temporariamente é a melhor solução para o problema. Caso até o fim da iteração outra solução melhor seja encontrada, então, esta será a nova solução para o problema. Ao atingir o valor máximo de iterações, a última melhor solução encontrada é retornada e exibida.

1.	Método HGARC (Max_iteracoes)
2.	Método Contrói_LRC (Max_Culturas)
3.	Para i = 1 até numCulturas Faça
4.	lucroCultura(i) = lucroTotalCultura(i)/ numeroCiclo(i)
5.	Atualiza LRC
6.	Fim para
7.	Ordenar as Culturas

```

8.   Retorna LRC
9.   Carrega informações das culturas
10.  Para k= 1 até Max_ iterações Faça
11.      Solução = Ø
12.      Constrói uma lista restrita de candidatos (LRC)
13.       $\alpha$  é determinado aleatoriamente
14.      LRC =  $\alpha$  * LRC
15.      Método construtivo()
16.          Enquanto (todas as posições da matriz não estiverem ocupadas) Faça
17.              Para cada i = 1 até número de linhas (lotes) da matriz Faça
18.                  Seleciona aleatoriamente um elemento s da LRC
19.                  S(i) = S(i) U s
20.              Fim Enquanto
21.              Retorna (solução)
22.      Fim construtivo()
23.      Constrói uma lista restrita de candidatos (LRC)
24.      Método buscaLocal (solução)
25.          Se (numIterações é menor que 50) Então
26.              LRC = LRC em ordem decrescente
27.          Senão
28.               $\alpha$  é determinado aleatoriamente
29.              Enquanto (numIterações não for o máximo escolhido) Faça
30.                  Escolha aleatoriamente um elemento x da LRC
31.                  Se somaTotal(solução U x) > somaTotal(solução) Então
32.                      solução = solução U x
33.                  Fim se
34.              Fim Enquanto
35.          Retorna solução
36.      Fim buscaLocal()
37.  Fim para
38.  Fim HGARC

```

Figura 8: Pseudocódigo do procedimento HGARC para o problema da rotação de culturas.

Neste trabalho, a função objetivo utilizada no HGARC é descrita pela Equação (1) abaixo que calcula o lucro total de cada solução final com base nas informações inseridas de cada cultura. Onde lf é referente ao lucro final da melhor solução que se dá ao realizar o somatório do lucro de uma cultura i em um período j de plantio multiplicado pela área pertencente ao lote k . As variáveis C , P e A referem-se ao conjunto de Culturas, Períodos de plantio de cada cultura e Tamanho da área de plantio, respectivamente.

$$\text{Maximize } lf = \sum_{i \in C} \sum_{j \in P} \sum_{k \in A} \text{lucro}_{ij} \text{ area}_k$$

5 RESULTADOS

Neste capítulo serão explicitados os dados utilizados para encontrar as soluções desde trabalho. As soluções retornadas ao executar o HGARC serão apresentadas adiante. Os seguintes parâmetros foram utilizados para gerar as soluções:

Tabela 4: Informações dos parâmetros aplicados ao HGARC.

Lotes	Iterações	Tempo médio da execução (segundos)
10 (12 meses)	200	15
15 (12 meses)	200	21,7
20 (12 meses)	200	23,1
16 (24 meses)	200	25,5

Fonte: elaborado pela autora.

A primeira abordagem, descrita em (FILHO,2012) se refere ao problema com restrição de demanda, lucratividade e produtividade variáveis. Esta foi feita utilizando a quantidade de lotes com valores de 10, 15 e 20 lotes em 12 meses e 16 lotes com 24 meses de cultivo. Como o objetivo é encontrar o maior lucro que possa ser retornado ao agricultor, não foi designado um limite de parada para o tamanho do lucro, foi determinado um limite apenas para o número de iterações.

Em uma única execução do código são gerados diversos resultados, ou seja, diversas matrizes com seus valores máximos encontrados após a finalização da busca local. Dessa forma é possível fazer uma comparação entre os resultados e analisar porque os resultados foram discrepantes, o que poderia ser melhorado ou o que poderia ser retirado. Como foi explicitado anteriormente, foi inserida a época de demanda de cada cultura para que os resultados fossem mais de acordo com a realidade, porém, esta adição também aumenta a dificuldade de desenvolvimento do algoritmo devido ao aumento de restrições que devem ser implementadas.

Para gerar melhores resultados e tirar o maior proveito dos lotes nos quais as culturas serão plantadas, o algoritmo foi desenvolvido a fim de que em todos os meses do ano o lote esteja sendo usado, ou seja, alguma cultura está sendo cultivada ou o solo está descansando com pousio. Para a execução do algoritmo, foram utilizados os dados que compõem a tabela 5. Na Tabela 5 são ilustradas todas as informações das culturas, onde a primeira coluna é o Id de cada cultura que aparece nas matrizes com as soluções, a segunda os nomes das culturas, em seguida a qual família pertence, épocas de plantio e ciclos de vida (ARAÚJO; MAURI, 2013).

Tabela 5: Informações das culturas.

Id	Cultura	Família	Época de Plantio		Ciclo de vida (t _i)
			Início	Fim	
1	Alface	1 Compositae	Ano todo		2
2	Almeirão	1 Compositae	Ano todo		4
3	Couve	2 Brassicaceae	Março	Julho	3
4	Brócolis	2 Brassicaceae	Fevereiro	Julho	7
5	Repolho	2 Brassicaceae	Fevereiro	Julho	4
6	Couve-Flor	2 Brassicaceae	Março	Julho	4
7	Beterraba	3 Chenopodiaceae	Março	Julho	2
8	Espinafre	3 Chenopodiaceae	Fevereiro	Julho	2
9	Abobrinha	4 Cucurbitaceae	Agosto	Março	4
10	Moranga	4 Cucurbitaceae	Setembro	Janeiro	5
11	Pepino	4 Cucurbitaceae	Ano todo		4
12	Melancia	4 Cucurbitaceae	Agosto	Outubro	3
13	Alho	5 Liliaceae	Março	Abril	6

14	Cebola	5 <i>Liliaceae</i>	Março	Junho	4
15	Quiabo	6 <i>Malvaceae</i>	Agosto	Março	7
16	Milho	7 <i>Gramineae</i>	Agosto	Abril	3
17	Aveia	7 <i>Gramineae</i>	Março	Maio	6
18	Tomate	8 <i>Solanaceae</i>	Ano todo		5
19	Pimentão	8 <i>Solanaceae</i>	Ano todo		5
20	Batata	8 <i>Solanaceae</i>	Agosto	Outubro	3
21	Cenoura	9 <i>Umbelliferae</i>	Março	Julho	4
22	Salsinha	9 <i>Umbelliferae</i>	Setembro	Março	6
23	Feijão-Vagem	10 <i>Leguminosae</i>	Agosto	Abril	4
24	Ervilha	10 <i>Leguminosae</i>	Março	Abril	3
25	Feijão	10 <i>Leguminosae</i>	Agosto	Setembro	3
26	Crotalaria	10 <i>Leguminosae</i>	Setembro	Dezembro	3
27	Feijão-de-Porco	10 <i>Leguminosae</i>	Setembro	Dezembro	3
28	Mucuna	10 <i>Leguminosae</i>	Setembro	Janeiro	3
29	Ervilha Peluda	10 <i>Leguminosae</i>	Março	Junho	4
30	Pousio	-	Ano todo		1

Fonte: FILHO, 2012.

Cada lote possui um determinado tamanho que é apresentado na Tabela 6 sendo válidos apenas para 10, 15 e 20 lotes.

Tabela 6: Tamanho dos lotes (hectare).

Lote	Área	Lote	Área
1	1,50	11	2,00
2	2,00	12	3,00
3	2,00	13	4,00
4	2,25	14	3,00
5	3,00	15	5,50
6	3,00	16	2,50
7	3,00	17	3,75
8	4,00	18	5,00
9	4,00	19	3,75
10	8,25	20	2,50

Fonte: FILHO, 2012.

Já para o problema com 16 lotes e 24 meses a tabela abaixo contém os tamanhos dos lotes.

Tabela 7: Tamanho dos lotes reais para matriz com 16 lotes (hectare).

Lote	Área	Lote	Área
1	0,2	11	0,20
2	0,3	12	0,30
3	0,25	13	0,25
4	0,25	14	0,25
5	0,28	15	0,20
6	0,42	16	0,30
7	0,35	17	0,25
8	0,35	18	0,25

Fonte: FILHO, 2012.


A lucratividade utilizada para as soluções com restrição de demanda está contida na tabela 8.

Tabela 8: Lucratividade mensal das culturas por metro quadrado (R\$).

Cultura	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
Alface	4	4	4	4	3	3	3	3	4	4	4	4
Almeirão	4	4	4	4	3	3	3	3	4	4	4	4
Couve	-	-	-	-	-	4	3	3	3	-	-	-
Brócolis	-	-	-	-	-				6	6	5	5
Repolho	-	-	-		-	6	5	5	5	6	6	-
Couve-Flor	-	-	-	-	-	-	-	5	5	6	-	-
Beterraba	-	-	-	-	0,9	0,9	0,9	0,8	0,8	-	-	-
Espinafre	-	-	-	10	10	10	6	6	6	-	-	-
Abobrinha	20	20	20	15	15	15	15	-	-	-	-	15
Moranga	15	20	20	20	20	20	-	-	-	-	-	-
Pepino	15	15	20	20	20	20	20	20	20	15	15	15
Melancia	50	-	-	-	-	-	-	-	-	-	30	30
Alho	-	-	-	-	-	-	-	-	4	4	-	-
Cebola	-	-	-	-	-	-	1	0,8	0,8	0,8	-	-
Quiabo	-	-	10	10	8	8	8	8	10	10	-	-
Milho	1	1	1	0,8	0,8	0,8	0,8	-	-	-	0,8	0,8
Aveia	-	-	-	-	-	-	-	-	0,8	0,8	1	-
Tomate	5	5	5	6	6	6	6	6	6	5	5	5
Pimentão	5	5	5	6	6	6	6	6	6	5	5	5
Batata	0,5	-	-	-	-	-	-	-	-	-	0,5	0,5
Cenoura	-	-	-	-	-	-	0,9	0,7	0,7	0,7	0,7	-
Salsinha	-	-	10	15	15	15	15	15	10	-	-	-
Feijão Vagem	0,2	0,2	0,2	0,2	0,15	0,15	0,15	0,2	-	-	-	0,2
Ervilha	-	-	-	-	-	0,15	0,15	-	-	-	-	-
Feijão	-	-	-	-	-	-	-	-	-	-	0,2	0,2

Fonte: Filho, 2012.

A seguir, na Figura 10 estão as configurações para 10, 15 e 20 lotes. Na Figura 11 está a configuração para 16 lotes.

**Figura 9:** Configurações para 10, 15 e 20 lotes.

1	5	9	13
2	6	10	14
3	7	11	15
4	8	12	16

Figura 10: Configuração para 16 lotes.

A seguir serão exibidas as soluções encontradas. Cada coluna da matriz representa um mês do ano, começando em janeiro e terminando em dezembro, cada linha representa um lote e os números correspondem à Tabela 4 que contém as informações das culturas. Todo lote deve ter no mínimo uma leguminosa e um pousio. Cada quadrado foi colorido com uma cor apenas para facilitar a configuração e a visão das culturas e não possuem um padrão estabelecido. Cada cultura está representada por um valor numérico e possui a mesma cor em todas as matrizes abaixo. Como foi explicitado anteriormente nas restrições que devem ser seguidas para ocorrer o plantio da rotação de culturas, cada linha (lote) possui ao menos um pousio que é representado pelo valor 30 (apenas para facilitar a representação da solução) e também em cada lote deve haver ao menos uma leguminosa, que são representadas pelos valores acima de 25.

A Tabela 9 contém os resultados encontrados para a abordagem com restrição de demanda e lucratividade variável para resultados com 10, 15 e 20 lotes.

Tabela 9: Resultados com solução inicial e melhor solução após a busca local aplicando o HGARC.

Quantidade de lotes	Solução Inicial (R\$)	Solução após busca local - Lucratividade (R\$)	Melhora (%)
10	R\$ 1.050.055,00	R\$ 1.276.000,00	21,51
15	R\$ 1.590.000,00	R\$ 1.826.000,00	14,84
20	R\$ 2.050.500,00	R\$ 2.420.000,00	18,01

Fonte: Elaborado pela autora.

Na Tabela 10 está contido o resultado para 16 lotes em 24 meses de plantio, para solução inicial e para respectiva busca local, a qual é a melhor solução encontrada para o problema explicitado.

Tabela 10: Resultados com solução inicial e após a busca local aplicando o HGARC.

Quantidade de lotes	Solução Inicial (R\$)	Solução após busca local - Lucratividade (R\$) para 16 lotes e 24 meses	Melhora (%)
16 lotes	R\$ 4.055.250,00	R\$ 5.055.700,00	24,67

Fonte: Elaborado pela autora.

Com base nos resultados descritos anteriormente, a tabela abaixo foi desenvolvida para simplificar a comparação dos resultados desta pesquisa com (FILHO 2012) que utilizou as

mesmas restrições de plantio.

Tabela 11: Comparação dos resultados de FILHO (2012) com o HGARC.

Método	GRASP	Algoritmo Genético (AG)	Simulated Annealing (SA)	AG + SA	Memético
Valor(R\$)	R\$ 5.055.700,00	R\$ 1.916.700,00	R\$ 2.080.100,00	R\$ 2.550.930,00	R\$ 2.245.300,00
Melhora (%)	-	163,71	143,05	98,13	125,16

Fonte: elaborado pela autora com dados de FILHO, 2012.

Nas figuras 11, 12 e 13 a seguir são exibidos os resultados para as matrizes com 12 meses e 10, 15 e 20 lotes, respectivamente. Todos esses resultados citados foram concebidos utilizando restrição de demanda.

	JAN	FEV	MAR	ABR	MAIO	JUN	JUL	AGO	SET	OUT	NOV	DEZ
1	1.0	1.0	30.0	9.0	9.0	9.0	9.0	30.0	28.0	28.0	28.0	30.0
2	30.0	30.0	29.0	29.0	29.0	29.0	30.0	30.0	2.0	2.0	2.0	2.0
3	30.0	30.0	2.0	2.0	2.0	2.0	7.0	7.0	27.0	27.0	27.0	30.0
4	23.0	23.0	23.0	23.0	8.0	8.0	1.0	1.0	30.0	1.0	1.0	30.0
5	16.0	16.0	16.0	30.0	30.0	3.0	3.0	3.0	26.0	26.0	26.0	30.0
6	23.0	23.0	23.0	23.0	30.0	18.0	18.0	18.0	18.0	18.0	1.0	1.0
7	30.0	30.0	2.0	2.0	2.0	2.0	8.0	8.0	26.0	26.0	26.0	30.0
8	23.0	23.0	23.0	23.0	7.0	7.0	30.0	18.0	18.0	18.0	18.0	18.0
9	19.0	19.0	19.0	19.0	19.0	30.0	7.0	26.0	26.0	26.0	26.0	30.0
10	1.0	1.0	30.0	30.0	23.0	23.0	23.0	23.0	11.0	11.0	11.0	11.0

Figura 11: Matriz com 10 Lotes e 12 meses. Lucratividade: R\$1.276.000,00

	JAN	FEV	MAR	ABR	MAIO	JUN	JUL	AGO	SET	OUT	NOV	DEZ
1	9.0	9.0	9.0	9.0	8.0	8.0	1.0	1.0	27.0	27.0	27.0	30.0
2	23.0	23.0	23.0	23.0	1.0	1.0	30.0	21.0	21.0	21.0	21.0	30.0
3	30.0	16.0	16.0	16.0	7.0	7.0	1.0	1.0	28.0	28.0	28.0	30.0
4	23.0	23.0	23.0	23.0	11.0	11.0	11.0	11.0	1.0	1.0	30.0	30.0
5	1.0	1.0	30.0	30.0	30.0	3.0	3.0	3.0	27.0	27.0	27.0	30.0
6	30.0	30.0	29.0	29.0	29.0	29.0	21.0	21.0	21.0	21.0	30.0	30.0
7	9.0	9.0	9.0	9.0	7.0	7.0	1.0	1.0	26.0	26.0	26.0	30.0
8	23.0	23.0	23.0	23.0	1.0	1.0	30.0	19.0	19.0	19.0	19.0	19.0
9	10.0	10.0	10.0	10.0	10.0	30.0	1.0	1.0	27.0	27.0	27.0	30.0
10	16.0	16.0	16.0	30.0	23.0	23.0	23.0	23.0	2.0	2.0	2.0	2.0
11	23.0	23.0	23.0	23.0	16.0	16.0	16.0	30.0	2.0	2.0	2.0	2.0
12	16.0	16.0	16.0	8.0	8.0	3.0	3.0	3.0	26.0	26.0	26.0	30.0
13	23.0	23.0	23.0	23.0	30.0	19.0	19.0	19.0	19.0	19.0	1.0	1.0
14	30.0	1.0	1.0	16.0	16.0	16.0	8.0	8.0	27.0	27.0	27.0	30.0
15	23.0	23.0	23.0	23.0	30.0	30.0	19.0	19.0	19.0	19.0	19.0	30.0

Figura 12: Matriz com 15 Lotes e 12 meses. Lucratividade: R\$ 1.826.000,00.

	JAN	FEV	MAR	ABR	MAIO	JUN	JUL	AGO	SET	OUT	NOV	DEZ
1	19.0	19.0	19.0	19.0	19.0	3.0	3.0	3.0	26.0	26.0	26.0	30.0
2	1.0	1.0	29.0	29.0	29.0	29.0	11.0	11.0	11.0	11.0	30.0	30.0
3	18.0	18.0	18.0	18.0	18.0	7.0	7.0	30.0	27.0	27.0	27.0	30.0
4	23.0	23.0	23.0	23.0	30.0	30.0	19.0	19.0	19.0	19.0	19.0	30.0
5	30.0	30.0	9.0	9.0	9.0	9.0	8.0	8.0	28.0	28.0	28.0	30.0
6	1.0	1.0	29.0	29.0	29.0	29.0	3.0	3.0	3.0	30.0	1.0	1.0
7	16.0	16.0	16.0	8.0	8.0	30.0	1.0	1.0	28.0	28.0	28.0	30.0

8	23.0	23.0	23.0	23.0	1.0	1.0	30.0	18.0	18.0	18.0	18.0	18.0
9	16.0	16.0	16.0	8.0	8.0	30.0	30.0	30.0	28.0	28.0	28.0	30.0
10	11.0	11.0	11.0	11.0	23.0	23.0	23.0	23.0	1.0	1.0	30.0	30.0
11	1.0	1.0	29.0	29.0	29.0	29.0	30.0	30.0	11.0	11.0	11.0	11.0
12	9.0	9.0	9.0	9.0	1.0	1.0	30.0	30.0	27.0	27.0	27.0	30.0
13	1.0	1.0	29.0	29.0	29.0	29.0	30.0	18.0	18.0	18.0	18.0	18.0
14	16.0	16.0	16.0	30.0	30.0	3.0	3.0	3.0	27.0	27.0	27.0	30.0
15	23.0	23.0	23.0	23.0	7.0	7.0	1.0	1.0	30.0	30.0	1.0	1.0
16	30.0	30.0	11.0	11.0	11.0	11.0	1.0	1.0	28.0	28.0	28.0	30.0
17	30.0	30.0	29.0	29.0	29.0	29.0	11.0	11.0	11.0	11.0	1.0	1.0
18	16.0	16.0	16.0	8.0	8.0	30.0	30.0	30.0	27.0	27.0	27.0	30.0
19	1.0	1.0	29.0	29.0	29.0	29.0	30.0	30.0	2.0	2.0	2.0	2.0
20	10.0	10.0	10.0	10.0	10.0	30.0	30.0	30.0	27.0	27.0	27.0	30.0

Figura 13: Matriz com 20 Lotes e 12 meses. Lucratividade: R\$ 2.420.000,00.

Também foi encontrada uma matriz que retornasse resultado para mais de um ano de plantio como na figura 14 a seguir, contendo 24 meses e 16 lotes, também com restrição de demanda. Além do resultado para 36 meses e 16 lotes (Figura 15) a fim de demonstrar que o GRASP pode ser aplicado em problemas com configurações de resultados variados.

	JAN	FEV	MA R	AB R	MAI O	JUN	JUL	AG O	SET	OU T	NO V	DEZ	JAN	FEV	MA R	AB R	MAI O	JUN	JUL	AG O	SET	OU T	NO V	DEZ
1	9.0	9.0	9.0	9.0	1.0	1.0	11.0	11.0	11.0	11.0	23.0	23.0	23.0	23.0	9.0	9.0	9.0	9.0	23.0	23.0	23.0	23.0	30.0	30.0
2	23.0	23.0	23.0	23.0	30.0	5.0	5.0	5.0	5.0	30.0	19.0	19.0	19.0	19.0	16.0	16.0	16.0	5.0	5.0	5.0	5.0	5.0	1.0	1.0
3	11.0	11.0	11.0	11.0	8.0	8.0	1.0	1.0	27.0	27.0	27.0	30.0	9.0	9.0	9.0	9.0	2.0	2.0	2.0	2.0	30.0	26.0	26.0	26.0
4	1.0	1.0	29.0	29.0	29.0	29.0	3.0	3.0	3.0	30.0	16.0	16.0	16.0	30.0	16.0	16.0	16.0	8.0	8.0	5.0	5.0	5.0	5.0	30.0
5	2.0	2.0	2.0	2.0	8.0	8.0	30.0	8.0	8.0	30.0	16.0	16.0	16.0	30.0	29.0	29.0	29.0	29.0	5.0	5.0	5.0	5.0	1.0	1.0
6	9.0	9.0	9.0	9.0	30.0	1.0	1.0	30.0	27.0	27.0	27.0	11.0	11.0	11.0	11.0	8.0	8.0	1.0	1.0	30.0	26.0	26.0	26.0	30.0
7	2.0	2.0	2.0	2.0	30.0	3.0	3.0	3.0	1.0	1.0	20.0	20.0	20.0	23.0	23.0	23.0	23.0	5.0	5.0	5.0	5.0	30.0	1.0	1.0
8	16.0	16.0	16.0	30.0	8.0	8.0	1.0	1.0	26.0	26.0	26.0	11.0	11.0	11.0	11.0	30.0	1.0	1.0	21.0	21.0	21.0	21.0	30.0	30.0
9	30.0	19.0	19.0	19.0	19.0	19.0	1.0	1.0	27.0	27.0	27.0	1.0	1.0	30.0	22.0	22.0	22.0	22.0	22.0	22.0	27.0	27.0	27.0	30.0
10	9.0	9.0	9.0	9.0	7.0	7.0	11.0	11.0	11.0	11.0	30.0	23.0	23.0	23.0	23.0	9.0	9.0	9.0	9.0	5.0	5.0	5.0	5.0	30.0
11	1.0	1.0	16.0	16.0	16.0	1.0	1.0	30.0	26.0	26.0	26.0	30.0	19.0	19.0	19.0	19.0	19.0	2.0	2.0	2.0	2.0	26.0	26.0	26.0
12	23.0	23.0	23.0	23.0	30.0	30.0	3.0	3.0	3.0	1.0	1.0	16.0	16.0	16.0	15.0	15.0	15.0	15.0	15.0	15.0	15.0	1.0	1.0	30.0
13	23.0	23.0	23.0	23.0	16.0	16.0	16.0	5.0	5.0	5.0	5.0	30.0	10.0	10.0	10.0	10.0	10.0	30.0	7.0	7.0	1.0	1.0	30.0	30.0
14	16.0	16.0	16.0	30.0	2.0	2.0	2.0	2.0	27.0	27.0	27.0	2.0	2.0	2.0	2.0	8.0	8.0	30.0	21.0	21.0	21.0	21.0	1.0	1.0
15	23.0	23.0	23.0	23.0	30.0	8.0	8.0	21.0	21.0	21.0	21.0	30.0	10.0	10.0	10.0	10.0	10.0	3.0	3.0	3.0	11.0	11.0	11.0	11.0
16	11.0	11.0	11.0	11.0	16.0	16.0	16.0	30.0	28.0	28.0	28.0	18.0	18.0	18.0	18.0	18.0	1.0	1.0	30.0	21.0	21.0	21.0	21.0	30.0

Figura 14: Matriz com 16 Lotes e 24 meses. Lucratividade: R\$ 5.055.700,00.

	JA N	FE V	MA R	AB R	MA I	JU N	JUL	AG O	SE T	OU T	NO V	DE Z	JA N	FE V	MA R	AB R	MA I	JU N	JUL	AG O	SE T	OU T	NO V	DE Z	JA N	FE V	MA R	AB R	MA I	JU N	JUL	AG O	SE T	OU T	NO V	DE Z
1	16.0	16.0	16.0	11.0	11.0	11.0	11.0	30.0	27.0	27.0	27.0	30.0	16.0	16.0	16.0	30.0	30.0	8.0	8.0	30.0	26.0	26.0	26.0	30.0	16.0	16.0	16.0	19.0	19.0	19.0	19.0	19.0	27.0	27.0	27.0	30.0
2	1.0	1.0	29.0	29.0	29.0	29.0	21.0	21.0	21.0	21.0	2.0	2.0	2.0	2.0	30.0	11.0	11.0	11.0	11.0	30.0	30.0	20.0	20.0	20.0	1.0	1.0	30.0	3.0	3.0	3.0	30.0	30.0	30.0	20.0	20.0	20.0
3	16.0	16.0	16.0	30.0	30.0	8.0	8.0	30.0	26.0	26.0	26.0	30.0	16.0	16.0	16.0	3.0	3.0	3.0	21.0	21.0	21.0	21.0	30.0	30.0	23.0	23.0	23.0	23.0	30.0	8.0	8.0	30.0	26.0	26.0	26.0	30.0
4	1.0	1.0	29.0	29.0	29.0	29.0	30.0	30.0	30.0	20.0	20.0	20.0	1.0	1.0	30.0	7.0	7.0	30.0	30.0	30.0	27.0	27.0	27.0	1.0	1.0	30.0	30.0	18.0	18.0	18.0	18.0	18.0	30.0	20.0	20.0	20.0
5	23.0	23.0	23.0	23.0	19.0	19.0	19.0	19.0	19.0	30.0	30.0	1.0	1.0	30.0	29.0	29.0	29.0	29.0	21.0	21.0	21.0	21.0	2.0	2.0	2.0	2.0	29.0	29.0	29.0	29.0	30.0	30.0	30.0	20.0	20.0	20.0
6	16.0	16.0	16.0	3.0	3.0	3.0	30.0	30.0	26.0	26.0	26.0	9.0	9.0	9.0	9.0	7.0	7.0	30.0	30.0	30.0	26.0	26.0	26.0	30.0	16.0	16.0	16.0	11.0	11.0	11.0	11.0	30.0	30.0	20.0	20.0	20.0
7	23.0	23.0	23.0	23.0	19.0	19.0	19.0	19.0	19.0	30.0	30.0	1.0	1.0	30.0	30.0	30.0	30.0	8.0	8.0	30.0	30.0	30.0	2.0	2.0	2.0	2.0	30.0	3.0	3.0	3.0	21.0	21.0	21.0	21.0	30.0	30.0
8	16.0	16.0	16.0	11.0	11.0	11.0	11.0	30.0	28.0	28.0	28.0	30.0	30.0	30.0	29.0	29.0	29.0	29.0	30.0	30.0	30.0	20.0	20.0	20.0	16.0	16.0	16.0	7.0	7.0	30.0	30.0	30.0	28.0	28.0	28.0	30.0
9	16.0	16.0	16.0	11.0	11.0	11.0	11.0	30.0	28.0	28.0	28.0	9.0	9.0	9.0	9.0	7.0	7.0	30.0	30.0	30.0	26.0	26.0	26.0	9.0	9.0	9.0	9.0	3.0	3.0	3.0	30.0	30.0	26.0	26.0	26.0	30.0
10	1.0	1.0	29.0	29.0	29.0	29.0	30.0	30.0	30.0	20.0	20.0	20.0	1.0	1.0	30.0	18.0	18.0	18.0	18.0	18.0	30.0	20.0	20.0	20.0	1.0	1.0	30.0	18.0	18.0	18.0	18.0	18.0	30.0	20.0	20.0	20.0
11	16.0	16.0	16.0	3.0	3.0	3.0	30.0	30.0	27.0	27.0	27.0	30.0	30.0	30.0	29.0	29.0	29.0	29.0	21.0	21.0	21.0	21.0	23.0	23.0	23.0	23.0	30.0	7.0	7.0	30.0	30.0	30.0	26.0	26.0	26.0	30.0
12	23.0	23.0	23.0	23.0	19.0	19.0	19.0	19.0	19.0	30.0	2.0	2.0	2.0	2.0	16.0	16.0	16.0	8.0	8.0	30.0	30.0	30.0	2.0	2.0	2.0	2.0	30.0	11.0	11.0	11.0	11.0	30.0	30.0	20.0	20.0	20.0
13	23.0	23.0	23.0	23.0	30.0	8.0	8.0	30.0	30.0	20.0	20.0	20.0	23.0	23.0	23.0	23.0	30.0	8.0	8.0	30.0	30.0	20.0	20.0	20.0	16.0	16.0	16.0	30.0	7.0	7.0	21.0	21.0	21.0	21.0	30.0	30.0
14	16.0	16.0	16.0	11.0	11.0	11.0	11.0	30.0	26.0	26.0	26.0	9.0	9.0	9.0	9.0	3.0	3.0	3.0	30.0	30.0	26.0	26.0	26.0	9.0	9.0	9.0	9.0	3.0	3.0	3.0	30.0	30.0	26.0	26.0	26.0	30.0
15	1.0	1.0	29.0	29.0	29.0	29.0	21.0	21.0	21.0	21.0	2.0	2.0	2.0	2.0	16.0	16.0	16.0	8.0	8.0	30.0	30.0	30.0	2.0	2.0	2.0	2.0	29.0	29.0	29.0	29.0	30.0	30.0	30.0	20.0	20.0	20.0
16	16.0	16.0	16.0	7.0	7.0	30.0	30.0	30.0	26.0	26.0	26.0	9.0	9.0	9.0	9.0	3.0	3.0	3.0	21.0	21.0	21.0	21.0	30.0	9.0	9.0	9.0	9.0	3.0	3.0	3.0	21.0	21.0	21.0	21.0	30.0	30.0

Figura 15: Matriz com 16 Lotes e 36 meses. Lucratividade: R\$ 5.808.000,00.

Abaixo são exibidos os resultados de (FILHO 2012) que foram gerados utilizando as mesmas restrições e função objetivo para obter lucratividade deste trabalho.

	Ano 1												Ano 2											
	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1	28	28	7	7	1	1	30	25	25	25	26	26	26	2	2	2	2	30	21	21	21	21	28	28
2	20	1	1	16	16	16	30	9	9	9	9	25	25	25	3	3	3	14	14	14	14	30	20	20
3	26	18	18	18	18	18	30	23	23	23	23	11	11	11	11	11	17	17	17	17	17	17	26	26
4	28	28	28	28	8	8	30	30	2	2	2	2	24	24	24	4	4	4	4	4	4	4	1	1
5	19	19	19	19	8	8	30	2	2	2	2	10	10	10	10	10	6	6	6	6	26	26	26	19
6	28	28	14	14	14	14	30	23	23	23	23	22	22	22	22	22	8	8	12	12	12	12	28	28
7	2	2	2	8	8	30	30	12	12	12	1	1	15	15	15	15	15	15	15	23	23	23	23	2
8	16	16	24	24	24	1	1	23	23	23	23	11	11	11	11	11	8	8	2	2	2	2	30	16
9	16	2	2	2	2	2	30	18	18	18	18	15	15	15	23	23	23	23	8	8	10	10	16	10
10	23	23	23	30	7	7	30	9	9	9	9	19	19	19	19	19	19	29	29	29	16	16	16	23
11	26	26	19	19	19	19	19	30	20	20	20	16	16	16	5	5	5	5	11	11	11	11	11	26
12	22	22	22	5	5	5	5	12	12	12	30	28	28	28	28	10	10	13	13	13	22	22	22	22
13	22	22	22	22	3	3	3	30	26	26	26	2	2	2	2	6	6	6	6	16	16	16	16	22
14	28	28	28	14	14	14	14	2	2	2	2	30	10	10	10	10	10	8	8	9	9	9	9	28
15	5	5	5	5	8	8	30	12	12	12	23	23	23	23	29	29	29	29	1	1	25	25	25	30
16	18	18	18	18	18	30	30	15	15	15	15	15	15	15	24	24	24	5	5	5	5	12	12	12

Figura 16: Melhor configuração para o Algoritmo Genético.

	Ano 1												Ano 2											
	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1	22	22	22	22	22	22	30	12	12	12	20	20	20	8	8	29	29	29	29	11	11	11	11	11
2	2	2	5	5	5	5	30	25	25	25	1	1	13	13	13	13	13	13	21	21	21	21	2	2
3	16	16	16	24	24	24	30	20	20	20	9	9	9	9	7	7	1	1	30	19	19	19	19	19
4	25	8	8	21	21	21	21	12	12	12	2	2	2	2	4	4	4	4	4	4	4	30	25	25
5	26	26	16	16	16	30	30	23	23	23	23	22	22	22	22	22	22	6	6	6	6	1	1	26
6	10	10	10	10	10	30	30	20	20	20	27	27	27	15	15	15	15	15	15	15	23	23	23	23
7	22	22	22	22	1	1	30	12	12	12	30	25	25	25	16	16	16	11	11	11	11	11	22	22
8	10	10	10	10	30	8	8	25	25	25	12	12	12	22	22	22	22	22	22	2	2	2	2	10
9	28	28	28	28	7	7	30	12	12	12	27	27	27	5	5	5	5	1	1	11	11	11	11	11
10	15	15	15	15	15	15	30	16	16	16	12	12	12	30	23	23	23	23	19	19	19	19	19	15
11	19	19	19	19	3	3	3	18	18	18	18	18	30	22	22	22	22	22	22	23	23	23	23	19
12	26	26	29	29	29	29	30	12	12	12	1	1	4	4	4	4	4	4	4	9	9	9	9	26
13	11	11	11	11	11	1	1	19	19	19	19	19	10	10	10	10	10	30	8	8	23	23	23	23
14	26	30	7	7	3	3	3	12	12	12	15	15	15	15	15	15	15	11	11	11	11	26	26	26
15	22	22	9	9	9	9	30	25	25	25	16	16	16	18	18	18	18	18	8	8	22	22	22	22
16	25	30	8	8	1	1	30	16	16	16	22	22	22	22	22	22	14	14	14	14	1	1	25	25

Figura 17: Melhor configuração para o *Simulated Annealing*.

	Ano 1												Ano 2											
	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1	22	22	22	22	22	22	30	12	12	12	20	20	20	8	8	29	29	29	29	11	11	11	11	11
2	2	2	5	5	5	5	30	25	25	25	1	1	13	13	13	13	13	13	21	21	21	21	2	2
3	16	16	16	24	24	24	30	20	20	20	9	9	9	9	7	7	1	1	30	19	19	19	19	19
4	25	8	8	21	21	21	21	12	12	12	2	2	2	2	4	4	4	4	4	4	4	30	25	25
5	26	26	16	16	16	30	30	23	23	23	23	22	22	22	22	22	22	6	6	6	6	1	1	26
6	10	10	10	10	10	30	30	20	20	20	27	27	27	15	15	15	15	15	15	15	23	23	23	23
7	22	22	22	22	1	1	30	12	12	12	30	25	25	25	16	16	16	11	11	11	11	11	22	22
8	10	10	10	10	30	8	8	25	25	25	12	12	12	22	22	22	22	22	22	2	2	2	2	10
9	28	28	28	28	7	7	30	12	12	12	27	27	27	5	5	5	5	1	1	11	11	11	11	11
10	15	15	15	15	15	15	30	16	16	16	12	12	12	30	23	23	23	23	19	19	19	19	19	15
11	19	19	19	19	3	3	3	18	18	18	18	18	30	22	22	22	22	22	22	23	23	23	23	19
12	26	26	29	29	29	29	30	12	12	12	1	1	4	4	4	4	4	4	4	9	9	9	9	26
13	11	11	11	11	11	1	1	19	19	19	19	19	10	10	10	10	10	30	8	8	23	23	23	23
14	26	30	7	7	3	3	3	12	12	12	15	15	15	15	15	15	15	11	11	11	11	26	26	26
15	22	22	9	9	9	9	30	25	25	25	16	16	16	18	18	18	18	18	8	8	22	22	22	22
16	25	30	8	8	1	1	30	16	16	16	22	22	22	22	22	22	14	14	14	14	1	1	25	25

Figura 18: Melhor configuração para o *Simulated Annealing* com Algoritmo Genético.

	Ano 1												Ano 2											
	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1	24	24	24	8	8	30	30	9	9	9	9	18	18	18	18	18	11	11	11	11	11	20	20	20
2	2	2	5	5	5	5	30	25	25	25	1	1	13	13	13	13	13	13	21	21	21	21	2	2
3	13	13	13	13	13	13	30	1	1	12	12	12	18	18	18	18	18	6	6	6	6	25	25	25
4	22	22	22	22	1	1	30	23	23	23	23	15	15	15	15	15	15	15	30	12	12	12	22	22
5	22	22	9	9	9	9	30	16	16	16	25	25	25	1	1	5	5	5	5	30	22	22	22	22
6	19	19	19	19	19	30	30	20	20	20	12	12	12	15	15	15	15	15	15	15	23	23	23	23
7	10	8	8	1	1	30	30	16	16	16	27	27	27	24	24	24	14	14	14	14	10	10	10	10
8	1	24	24	24	30	8	8	12	12	12	16	16	16	9	9	9	9	7	7	23	23	23	23	1
9	23	23	23	30	3	3	3	9	9	9	9	1	1	11	11	11	11	11	11	18	18	18	18	23
10	9	9	9	9	8	8	30	30	23	23	23	23	18	18	18	18	18	2	2	2	2	16	16	16
11	13	13	13	13	13	13	30	9	9	9	9	1	1	30	15	15	15	15	15	15	15	27	27	27
12	15	15	15	15	15	15	30	2	2	2	2	26	26	26	5	5	5	5	11	11	11	11	11	15
13	12	16	16	16	8	8	30	2	2	2	2	23	23	23	23	4	4	4	4	4	4	4	12	12
14	22	22	2	2	2	2	30	12	12	12	26	26	26	8	8	11	11	11	11	11	22	22	22	22
15	10	16	16	16	3	3	3	1	1	30	23	23	23	22	22	22	22	22	22	22	10	10	10	10
16	22	22	22	22	8	8	30	12	12	12	19	19	19	19	19	7	7	29	29	29	29	30	22	22

Figura 19: Melhor configuração para o Memético.

Como este estudo tem o de objetivo aproximar os resultados ao máximo da realidade, nestes resultados é possível verificar que nem todas as culturas foram utilizadas e isso pode ter ocorrido devido ao período de plantio e a época de demanda não estarem condizentes ou porque aquela cultura ao ser testada retornaria um valor menor que outras. No resultado anterior para um plantio de dois anos foram selecionadas pelo algoritmo culturas que não aparecem nos demais resultados devido à sua disponibilidade logística de plantio. Como pode ser visto, a Batata (20.0) necessita ser plantada de novembro a dezembro, logo, ao realizar a plantação em um período de janeiro a dezembro, não seria possível plantá-la. Apenas se fosse num período de dois anos. Também pode ser visto que algumas culturas como a alface (1.0) e o Pepino (11.0) aparecem com bastante frequência e isso acontece, pois, são culturas muito flexíveis tanto em suas épocas de demanda como de plantio.

A fim de demonstrar o bom desempenho da meta-heurística GRASP, o algoritmo foi modificado para se adaptar à outra abordagem mencionada para que assim os possam ser comparados. Nesta segunda abordagem os resultados foram obtidos para 10, 15 e 20 lotes a fim de que uma comparação com os resultados de (ARAÚJO E MAURI, 2013) pudesse ser desenvolvida. Os seguintes parâmetros foram utilizados:

Tabela 12: Informações dos parâmetros aplicados o HGARC.

Lotes	Iterações	Tempo médio da execução (segundos)
10	200	10,2
15	200	12,6
20	200	13,7

Fonte: elaborado pela autora.

Para a modificação foi retirada a restrição de demanda e permaneceram apenas as restrições de adjacências. O cálculo da lucratividade é realizado de modo diferente do modelo anterior. Neste a lucratividade de cada cultura é fixa, ou seja, durante todos os meses do ciclo de plantio, a cultura retorna um valor fixo de lucro. Este valor está descrito na última coluna da tabela abaixo.

Tabela 13: Informações das culturas com suas respectivas lucratividades fixas.

Id	Cultura	Família	Época de Plantio		Ciclo de vida (t _i)	Lucratividade (R\$)
			Início	Fim		
1	Alface	1 Compositae	Ano todo		2	300
2	Almeirão	1 Compositae	Ano todo		4	150
3	Couve	2 Brassicaceae	Março	Julho	3	300
4	Brócolis	2 Brassicaceae	Fevereiro	Julho	7	400
5	Repolho	2 Brassicaceae	Fevereiro	Julho	4	400
6	Couve-Flor	2 Brassicaceae	Março	Julho	4	900
7	Beterraba	3 Chenopodiaceae	Março	Julho	2	810
8	Espinafre	3 Chenopodiaceae	Fevereiro	Julho	2	600
9	Abobrinha	4 Cucurbitaceae	Agosto	Março	4	400
10	Moranga	4 Cucurbitaceae	Setembro	Janeiro	5	200
11	Pepino	4 Cucurbitaceae	Ano todo		4	450
12	Melancia	4 Cucurbitaceae	Agosto	Outubro	3	900
13	Alho	5 Liliaceae	Março	Abril	6	810
14	Cebola	5 Liliaceae	Março	Junho	4	430
15	Quiabo	6 Malvaceae	Agosto	Março	7	710
16	Milho	7 Gramineae	Agosto	Abril	3	350
17	Aveia	7 Gramineae	Março	Maio	6	350
18	Tomate	8 Solanaceae	Ano todo		5	810
19	Pimentão	8 Solanaceae	Ano todo		5	550
20	Batata	8 Solanaceae	Agosto	Outubro	3	240
21	Cenoura	9 Umbelliferae	Março	Julho	4	620
22	Salsinha	9 Umbelliferae	Setembro	Março	6	400
23	Feijão-Vagem	10 Leguminosae	Agosto	Abril	4	750
24	Ervilha	10 Leguminosae	Março	Abril	3	830
25	Feijão	10 Leguminosae	Agosto	Setembro	3	720
26	Crotalária	10 Leguminosae	Setembro	Dezembro	3	-
27	Feijão-de-Porco	10 Leguminosae	Setembro	Dezembro	3	-
28	Mucuna	10 Leguminosae	Setembro	Janeiro	3	-
29	Ervilha Peluda	10 Leguminosae	Março	Junho	4	-
30	Pousio	-	Ano todo		1	-

Fonte: FILHO. 2012.

Na tabela a seguir são exibidos os resultados encontrados para 10, 15 e 20 lotes durante um período de doze meses juntamente com a solução inicial gerada.

Tabela 14: Resultados com melhores soluções para restrição de adjacências em doze meses aplicando o HGARC.

Lotes	Solução Inicial (R\$)	Solução após busca local - Melhor Solução (R\$)	Solução Média (R\$)	Melhora (%)
10	R\$ 70.157,00	R\$ 78.327,50	R\$ 75.336,00	11,64
15	R\$ 101.397,50	R\$ 117.967,50	R\$ 114.960,50	16,34
20	R\$ 130.335,00	R\$ 156.985,00	R\$ 152.974,50	20,44

Fonte: elaborado pela autora.

É importante ressaltar que para a comparação com os resultados de (ARAÚJO; MAURI, 2013) os resultados das figuras 23, 24 e 25 são compostos por culturas que têm seu início no fim do ano e continuam a serem plantadas no início do ano seguinte, ou seja, não são plantadas em períodos adjacentes, o que de acordo com análises feitas não seria viável, pois, o objetivo é

o plantio em 12 meses e o ideal seria todas as culturas iniciarem e terminarem no prazo de um ano igualmente. Porém ao executar o algoritmo da forma que seria o ideal, ou seja, com o plantio todo em 12 meses, a lucratividade diminui em relação aos outros estudos encontrados na literatura. Dessa forma o algoritmo foi adaptado para que os resultados pudessem ser comparados com os de outros autores, utilizando o mesmo meio de alocação das culturas. A Tabela 15 contém os resultados da solução inicial e a respectiva solução final após a aplicar a busca local.

Tabela 15: Resultados com as melhores soluções para solução inicial e após aplicar a busca local na mesma aplicando o HGARC.

Lotes	Solução Inicial (R\$)	Solução após busca local – Melhor Solução (R\$)	Solução Média (R\$)	Melhora (%)
10	R\$ 73.290,50	R\$ 85.932,50	R\$ 83.532,00	17,24
15	R\$ 110.355,50	R\$ 130.195,00	R\$ 129.285,50	17,97
20	R\$ 155.195,00	R\$ 173.590,00	R\$ 173.170,00	11,85

Fonte: elaborado pela autora.

A Tabela 16 apresenta a comparação das médias dos resultados obtidos aplicando o HGARC com outros resultados da literatura sendo essa tabela com restrição de adjacências, sem restrição de demanda. As fontes comparadas são: Filho (2012) com Algoritmo Genético (AG), Simulated Annealing (SA), Algoritmo Memético (AM) e AG com SA; Araújo e Mauri (2013) com Clustering Search (CS). Também é possível notar como o GRASP obteve uma melhoria significativa em relação aos outros métodos citados.

Tabela 16: Comparação dos resultados do HGARC com a literatura.

Lotes/Método	GRASP	CS	AG	SA	AM	AG+SA
10	R\$ 83.298,50	R\$ 78.149,40	R\$ 55.022,00	R\$ 68.304,00	R\$ 55.369,00	R\$ 66.985,00
15	R\$ 129.285,50	R\$ 118.457,90	R\$ 74.910,00	R\$ 101.200,00	R\$ 86.916,00	R\$ 91.796,00
20	R\$ 173.170,00	R\$ 168.048,33	R\$ 90.590,00	R\$ 128.890,00	R\$ 119.140,00	R\$ 136.708,00
Total	R\$ 385.754,00	R\$ 364.655,63	R\$ 220.522,00	R\$ 298.394,00	R\$ 261.425,00	R\$ 295.489,00
Melhora (%)	-	5,78	74,92	29,27	47,55	30,54

Fonte: elaborado pela autora.

A seguir nas figuras 20, 21 e 22 são exibidos os resultados obtidos para o plantio em 12 meses utilizando a rotação de culturas.

	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
1	1.0	1.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	30.0	30.0
2	30.0	30.0	7.0	7.0	30.0	25.0	25.0	25.0	30.0	16.0	16.0	16.0
3	30.0	30.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	1.0	1.0
4	30.0	30.0	7.0	7.0	30.0	25.0	25.0	25.0	1.0	1.0	30.0	30.0
5	30.0	30.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	1.0	1.0
6	1.0	1.0	7.0	7.0	30.0	25.0	25.0	25.0	1.0	1.0	30.0	30.0
7	30.0	30.0	6.0	6.0	6.0	6.0	1.0	1.0	23.0	23.0	23.0	23.0
8	1.0	1.0	7.0	7.0	30.0	25.0	25.0	25.0	1.0	1.0	30.0	30.0
9	30.0	30.0	6.0	6.0	6.0	6.0	1.0	1.0	23.0	23.0	23.0	23.0
10	30.0	30.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	1.0	1.0

Figura 20: Resultado com restrição de adjacências para 10 lotes em 12 meses.

	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
1	1.0	1.0	30.0	7.0	7.0	1.0	1.0	30.0	23.0	23.0	23.0	23.0
2	30.0	30.0	24.0	24.0	24.0	30.0	30.0	12.0	12.0	12.0	30.0	30.0
3	1.0	1.0	7.0	7.0	30.0	25.0	25.0	25.0	16.0	16.0	16.0	30.0
4	30.0	30.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	1.0	1.0
5	1.0	1.0	7.0	7.0	30.0	25.0	25.0	25.0	30.0	16.0	16.0	16.0
6	30.0	30.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	1.0	1.0
7	30.0	30.0	7.0	7.0	1.0	1.0	30.0	30.0	23.0	23.0	23.0	23.0
8	30.0	30.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	1.0	1.0
9	1.0	1.0	7.0	7.0	1.0	1.0	30.0	30.0	23.0	23.0	23.0	23.0
10	18.0	18.0	18.0	18.0	18.0	25.0	25.0	25.0	1.0	1.0	30.0	30.0
11	30.0	30.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	1.0	1.0
12	1.0	1.0	30.0	7.0	7.0	25.0	25.0	25.0	16.0	16.0	16.0	30.0
13	30.0	30.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	1.0	1.0
14	30.0	30.0	7.0	7.0	1.0	1.0	30.0	30.0	23.0	23.0	23.0	23.0
15	30.0	30.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	1.0	1.0

Figura 21: Resultado com restrição de adjacências para 15 lotes em 12 meses.

	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
1	30.0	30.0	7.0	7.0	1.0	1.0	30.0	30.0	23.0	23.0	23.0	23.0
2	30.0	30.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	1.0	1.0
3	1.0	1.0	7.0	7.0	1.0	1.0	30.0	30.0	23.0	23.0	23.0	23.0
4	30.0	30.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	1.0	1.0
5	1.0	1.0	7.0	7.0	30.0	25.0	25.0	25.0	16.0	16.0	16.0	30.0
6	30.0	30.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	30.0	30.0
7	1.0	1.0	7.0	7.0	30.0	30.0	30.0	30.0	23.0	23.0	23.0	23.0

8	30.0	30.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	1.0	1.0
9	1.0	1.0	30.0	7.0	7.0	1.0	1.0	30.0	23.0	23.0	23.0	23.0
10	18.0	18.0	18.0	18.0	18.0	25.0	25.0	25.0	1.0	1.0	30.0	30.0
11	30.0	30.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	30.0	30.0
12	1.0	1.0	30.0	7.0	7.0	25.0	25.0	25.0	16.0	16.0	16.0	30.0
13	30.0	30.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	1.0	1.0
14	1.0	1.0	7.0	7.0	30.0	30.0	30.0	30.0	23.0	23.0	23.0	23.0
15	30.0	30.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	1.0	1.0
16	1.0	1.0	30.0	7.0	7.0	25.0	25.0	25.0	16.0	16.0	16.0	30.0
17	30.0	30.0	24.0	24.0	24.0	7.0	7.0	30.0	23.0	23.0	23.0	23.0
18	1.0	1.0	7.0	7.0	30.0	25.0	25.0	25.0	30.0	30.0	30.0	30.0
19	30.0	30.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	1.0	1.0
20	1.0	1.0	7.0	7.0	30.0	25.0	25.0	25.0	30.0	30.0	30.0	30.0

Figura 22: Resultado com restrição de adjacências para 20 lotes em 12 meses.

Os resultados das figuras 23, 24 e 25 ilustram, respectivamente, os melhores resultados obtidos pelo GRASP para 10, 15 e 20 lotes com culturas plantadas em períodos não adjacentes.

	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
1	1.0	1.0	24.0	24.0	24.0	7.0	7.0	12.0	12.0	12.0	30.0	30.0
2	18.0	8.0	8.0	30.0	30.0	25.0	25.0	25.0	18.0	18.0	18.0	18.0
3	23.0	23.0	23.0	23.0	7.0	7.0	30.0	12.0	12.0	12.0	30.0	30.0
4	30.0	30.0	6.0	6.0	6.0	6.0	30.0	23.0	23.0	23.0	23.0	30.0
5	1.0	1.0	24.0	24.0	24.0	8.0	8.0	12.0	12.0	12.0	30.0	30.0
6	18.0	30.0	7.0	7.0	30.0	25.0	25.0	25.0	18.0	18.0	18.0	18.0
7	1.0	1.0	24.0	24.0	24.0	8.0	8.0	12.0	12.0	12.0	30.0	30.0
8	18.0	18.0	30.0	30.0	7.0	7.0	25.0	25.0	25.0	18.0	18.0	18.0
9	1.0	1.0	24.0	24.0	24.0	8.0	8.0	12.0	12.0	12.0	30.0	30.0
10	23.0	30.0	7.0	7.0	18.0	18.0	18.0	18.0	18.0	23.0	23.0	23.0

Figura 23: Resultado com restrição de adjacências para 10 em períodos não adjacentes.

	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
1	1.0	1.0	7.0	7.0	1.0	1.0	30.0	23.0	23.0	23.0	23.0	30.0
2	16.0	30.0	24.0	24.0	24.0	7.0	7.0	1.0	1.0	30.0	16.0	16.0
3	18.0	30.0	7.0	7.0	30.0	25.0	25.0	25.0	18.0	18.0	18.0	18.0
4	16.0	30.0	24.0	24.0	24.0	7.0	7.0	1.0	1.0	30.0	16.0	16.0
5	1.0	1.0	7.0	7.0	1.0	1.0	30.0	23.0	23.0	23.0	23.0	30.0
6	16.0	30.0	24.0	24.0	24.0	7.0	7.0	1.0	1.0	30.0	16.0	16.0
7	23.0	30.0	7.0	7.0	18.0	18.0	18.0	18.0	18.0	23.0	23.0	23.0
8	16.0	30.0	24.0	24.0	24.0	7.0	7.0	1.0	1.0	30.0	16.0	16.0

9	23.0	30.0	1.0	1.0	18.0	18.0	18.0	18.0	18.0	23.0	23.0	23.0
10	30.0	30.0	7.0	7.0	30.0	25.0	25.0	25.0	7.0	7.0	30.0	30.0
11	1.0	1.0	24.0	24.0	24.0	7.0	7.0	1.0	1.0	30.0	30.0	30.0
12	18.0	30.0	7.0	7.0	30.0	25.0	25.0	25.0	18.0	18.0	18.0	18.0
13	1.0	1.0	24.0	24.0	24.0	7.0	7.0	1.0	1.0	30.0	30.0	30.0
14	23.0	30.0	7.0	7.0	18.0	18.0	18.0	18.0	18.0	23.0	23.0	23.0
15	16.0	30.0	24.0	24.0	24.0	7.0	7.0	1.0	1.0	30.0	16.0	16.0

Figura 24: Resultado com restrição de adjacências para 15 lotes em períodos não adjacentes.

	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
1	23.0	23.0	7.0	7.0	1.0	1.0	30.0	12.0	12.0	12.0	23.0	23.0
2	1.0	1.0	24.0	24.0	24.0	7.0	7.0	25.0	25.0	25.0	30.0	30.0
3	23.0	23.0	7.0	7.0	1.0	1.0	30.0	12.0	12.0	12.0	23.0	23.0
4	1.0	1.0	24.0	24.0	24.0	8.0	8.0	25.0	25.0	25.0	30.0	30.0
5	23.0	23.0	7.0	7.0	1.0	1.0	30.0	12.0	12.0	12.0	23.0	23.0
6	1.0	1.0	24.0	24.0	24.0	8.0	8.0	25.0	25.0	25.0	30.0	30.0
7	23.0	23.0	7.0	7.0	1.0	1.0	30.0	12.0	12.0	12.0	23.0	23.0
8	18.0	18.0	18.0	18.0	18.0	25.0	25.0	25.0	1.0	1.0	30.0	30.0
9	23.0	23.0	7.0	7.0	1.0	1.0	30.0	12.0	12.0	12.0	23.0	23.0
10	30.0	30.0	24.0	24.0	24.0	7.0	7.0	18.0	18.0	18.0	18.0	18.0
11	1.0	1.0	24.0	24.0	24.0	8.0	8.0	25.0	25.0	25.0	30.0	30.0
12	23.0	23.0	7.0	7.0	1.0	1.0	30.0	12.0	12.0	12.0	23.0	23.0
13	1.0	1.0	24.0	24.0	24.0	7.0	7.0	25.0	25.0	25.0	30.0	30.0
14	23.0	23.0	7.0	7.0	1.0	1.0	30.0	12.0	12.0	12.0	23.0	23.0
15	18.0	18.0	18.0	18.0	18.0	25.0	25.0	25.0	1.0	1.0	30.0	30.0
16	23.0	23.0	7.0	7.0	1.0	1.0	30.0	12.0	12.0	12.0	23.0	23.0
17	1.0	1.0	24.0	24.0	24.0	8.0	8.0	25.0	25.0	25.0	30.0	30.0
18	23.0	23.0	7.0	7.0	1.0	1.0	30.0	12.0	12.0	12.0	23.0	23.0
19	1.0	1.0	24.0	24.0	24.0	8.0	8.0	25.0	25.0	25.0	30.0	30.0
20	23.0	23.0	7.0	7.0	1.0	1.0	30.0	12.0	12.0	12.0	23.0	23.0

Figura 25: Resultado com restrição de adjacências para 20 lotes em períodos não adjacentes.

As figuras abaixo contêm os resultados encontrados na literatura de Araújo e Mauri.

	Ano 1											
Lote/Mês	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1	30	8	8	6	6	6	6	30	25	25	25	30
2	16	30	24	24	24	7	7	12	12	12	16	16
3	1	1	7	7	6	6	6	6	25	25	25	30
4	23	23	23	23	7	7	30	12	12	12	1	1
5	1	1	7	7	6	6	6	6	25	25	25	30
6	23	23	23	1	1	7	7	12	12	12	30	23
7	1	1	7	7	6	6	6	6	25	25	25	30
8	16	30	30	24	24	24	21	21	21	21	16	16
9	1	1	7	7	6	6	6	6	25	25	25	30
10	23	23	23	1	1	7	7	12	12	12	30	23

Figura 26: Melhor programação para 10 lotes em períodos não adjacentes.

Fonte: ARAÚJO; MAURI, 2013.

	Ano 1											
Lote/Mês	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1	1	1	7	7	30	29	29	29	29	1	1	30
2	16	16	24	24	24	7	7	30	12	12	12	16
3	1	1	7	7	6	6	6	6	25	25	25	30
4	16	30	24	24	24	7	7	12	12	12	16	16
5	1	1	30	7	7	1	1	30	25	25	25	30
6	23	23	23	1	1	7	7	12	12	12	30	23
7	1	1	30	7	7	1	1	30	25	25	25	30
8	23	23	23	6	6	6	6	1	1	30	30	23
9	16	30	30	7	7	1	1	25	25	25	16	16
10	30	8	8	24	24	24	7	7	12	12	12	30
11	16	30	24	24	24	7	7	12	12	12	16	16
12	1	1	7	7	6	6	6	6	25	25	25	30
13	30	30	24	24	24	7	7	1	1	12	12	12
14	16	30	6	6	6	6	30	25	25	25	16	16
15	23	23	30	30	7	7	21	21	21	21	23	23

Figura 27: Melhor programação para 15 lotes em períodos não adjacentes.
Fonte: ARAÚJO; MAURI, 2013.

	Ano 1											
Lote/Mês	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
1	30	8	8	1	1	7	7	25	25	25	30	30
2	16	30	24	24	24	1	1	12	12	12	16	16
3	30	8	8	1	1	7	7	30	25	25	25	30
4	1	1	24	24	24	1	1	30	12	12	12	30
5	30	8	8	1	1	7	7	25	25	25	30	30
6	1	1	24	24	24	1	1	12	12	12	30	30
7	16	16	16	30	7	7	30	25	25	25	1	1
8	1	1	24	24	24	3	3	3	1	1	30	30
9	16	30	1	1	30	7	7	25	25	25	16	16
10	23	23	7	7	1	1	30	12	12	12	23	23
11	1	1	7	7	6	6	6	6	25	25	25	30
12	16	30	24	24	24	7	7	12	12	12	16	16
13	1	1	7	7	6	6	6	6	25	25	25	30
14	23	23	23	23	7	7	30	12	12	12	1	1
15	1	1	7	7	1	1	7	7	25	25	25	30
16	30	30	24	24	24	7	7	1	1	12	12	12
17	1	1	7	7	6	6	6	6	25	25	25	30
18	16	30	24	24	24	7	7	12	12	12	16	16
19	1	1	7	7	6	6	6	6	25	25	25	30
20	30	30	24	24	24	7	7	1	1	12	12	12

Figura 28: Melhor programação para 20 lotes em períodos não adjacentes.
Fonte: ARAÚJO; MAURI, 2013.

6 CONCLUSÃO

O objetivo deste trabalho é criar uma heurística para gerar soluções para o problema de rotação de culturas. Os resultados obtidos mostram que a HGARC conseguiu bons resultados quando comparados as outras heurísticas da literatura. Acreditamos que isto aconteceu pelas características do GRASP, visto que, gera uma nova solução a cada iteração e depois tenta refina-la. As outras heurísticas combinam soluções e este processo, é muito difícil, pois combinar soluções viáveis pode gerar soluções inviáveis. Além de não garantir a melhora das soluções.

Uma outra observação a ser feita é que as melhores soluções nem sempre são as que mais produzem alimentos. Isso acontece devido as diferenças dos valores retornados, visto que algumas culturas retornam valores muito altos e outros valores muito baixos. Portanto é melhor usar uma cultura de valor alto e deixar o solo descansando em outros meses, do que preencher todos os períodos com culturas de baixo valor.

Esta heurística tratou de dois tipos diferentes de problemas: com demanda e com lucratividade variável e sem demanda com lucratividade fixa. Esses com demanda desenvolvidos para se aproximarem mais da realidade de plantio tendo em vista que o cultivo só ocorrerá se houverem compradores, ou seja, procura-se ter o menor desperdício possível. Outra característica é que estes problemas possuem a lucratividade dependendo do mês de colheita, o que o torna mais real. Enquanto sem demanda os lucros de cada cultura são fixos, portanto, durante todo ciclo de plantio a lucratividade retornada é apenas uma.

Em ambos os resultados foi possível notar que algumas culturas aparecem com mais frequência que outras e isto ocorre devido a elas serem mais flexíveis em questão de época de plantio, ou seja, elas podem ser plantadas em muitas épocas do ano, enquanto outras são restritas a apenas poucos meses. Um exemplo seria a alface, representado pelo número 1, que aparece com grande frequência em todos os resultados e isso ocorre pelos motivos explicitados anteriormente, ela é uma cultura flexível, pode ser plantada o ano inteiro e o ciclo dura apenas dois meses, o que possibilita alocá-la em qualquer lote e período com espaços livres suficientes.

Este trabalho tenta simular que, com a ajuda da tecnologia, o agricultor pode alcançar níveis maiores de lucro, porque ao alocar as culturas certas no tempo e local adequados, o retorno se tornará maior. Além do plantio ecológico usando a rotação de culturas evitando assim diversos problemas apresentados na monocultura.

Para um trabalho futuro o GRASP poderia ser testado com problemas maiores, ou seja, com uma gama maior de culturas, lotes, períodos de plantio, entre outros. Também pode ser feita uma pesquisa de campo a fim de adquirir dados reais de todos os lotes, culturas e seus respectivos períodos de plantio e para tornar o resultado do trabalho mais real ainda.

7 REFERÊNCIAS BIBLIOGRÁFICAS

- ARAÚJO, D. L.; MAURI, G. R. **Clustering search para resolução de um problema de rotação de culturas com restrições de adjacências**. Universidade Federal do Espírito Santo - UFES 2013.
- CRUZ, M. D. **O problema de Clusterização Automática**. Tese de Doutorado. 2010. 120p. Tese (Doutorado). COPPE. Universidade Federal do Rio de Janeiro, Rio de Janeiro.
- DIAZ, A.; GLOVER, F.; GHAZIRI, H.; GONZÁLEZ, J. L.; LAGUNA, M.; MOSCATO, P.; TSENG, F. **Optimización Heurística Y Redes Neurolales**, Editorial Paraninfo, Espanha, 1996.
- DOS SANTOS, L. M. R; HENRIQUE SANTOS, R.; ARENALES, M. N.; RAGGI, L. A. **Um modelo para a programação de rotação de culturas**. Universidade Federal de Viçosa – UFV. Viçosa – MG. 2007
- EMBRAPA - Empresa Brasileira de Pesquisa Agropecuária. Rotação de Culturas. Disponível em: <<http://www.cnpso.embrapa.br/producaosoja/rotacao.htm/>>. Acesso em: 17 fev. 2016.
- FEO, T., RESENDE, M. **Greedy randomized adaptive search procedures**. Journal of Global Optimization, Ed. 6, p. 109-133. 1995.
- FILGUEIRA, F. A. R. **Novo Manual de Olericultura**. Viçosa: UFV, 2003.
- FILHO, A. A. **Meta-heurísticas Em Um Problema De Rotação De Culturas**. Universidade Estadual Paulista – UNESP. Botucatu - SP. 2012. p. 62.
- FRANCHINI, J. C., COSTA, M. J., DEBIASI, H., TORRES, H. **Importância da rotação de culturas para a produção agrícola sustentável no Paraná**. Embrapa Soja. Londrina – PR. 2011.
- FREDDO A. R., BRITO, R. C. **Implementação da Meta-heurística GRASP para o Problema do Caixeiro Viajante Simétrico**. Universidade Federal do Paraná. 2008.
- GOMES, R. M.; ARENALES, M. N. **Otimização linear aplicada ao plantio sustentável de vegetais**. Instituto de Ciências Matemáticas e de Computação – ICMC – USP. 2011.
- GLOVER, F., KOCHENBERGER, G. A. **Handbook of Metaheuristics**. Kluwer Academic Publishers, Boston. 2003.
- LACERDA, E. G. M. **Simulated Annealing**. DCA – UFRN. 2006.
- LUZIA, F. L., RODRIGUES M. C. **Introdução ao Escalonamento e Aplicações. Estudo sobre as Meta-heurísticas**. IME – USP. São Paulo, 2009.
- LANDMANN, R., ERDMANN, R. H. **Uma abordagem heurística para a programação da produção na indústria de fundição com utilização da lógica fuzzy**. Gest.Prod., São Carlos, v. 18, n. 1, p. 119-130, 2011.

MARIANI, C. M., HANKS, J. A. **Agricultura orgânica x agricultura convencional. Soluções para minimizar o uso de insumos industrializados.** Florianópolis – SC. 2015.

PAULA, M. E. **Utilização de Leguminosas nas práticas da adubação verde e rotação de culturas.** Jornal Dia de Campo – Disponível em: <http://www.diadecampo.com.br/zpublisher/materias/Materia.asp?id=21360&secao=Sementes%20e%20Mudas>. Acesso em: 13 de março de 2017.

PENTEADO, S.R. **Implantação do cultivo orgânico: planejamento e plantio.** 2a ed. Campinas: Via Orgânica, 2012.

RUSSELL, S.; NORVIG, P. **Inteligência Artificial.** 2ª Ed. Editora Campus, 2004.

SANTOS, H.P. dos; REIS, E. M. **Rotação De Culturas Em Plantio Direto.** Embrapa. Passo Fundo – RS. 2001.

SANTOS, R. H. S. **Olericultura: teoria e prática.** In: FONTES, P. C. R. (Ed.). Olericultura orgânica. Viçosa: Universidade Federal de Viçosa, 2005. p.249-276.

SILVA, G. C. da; OCHI, L. S.; MARTINS, S. L. **Proposta e Avaliação De Heurísticas Grasp Para O Problema Da Diversidade Máxima.** Instituto de Computação. Universidade Federal Fluminense (UFF). Niterói – RJ. 2005.

SOUZA, J. L.; RESENDE, P. L. **Manual de Horticultura Orgânica.** Viçosa: Aprenda Fácil, 2006.