

ESCOLA POLITÉCNICA DA UNIVERSIDADE DE SÃO PAULO

MACHINE LEARNING CONTROL

Bruno Henrique Koga Fazano - 9835345

João Vitor Almeida Kuhn - 10336296

São Paulo, dezembro de 2020

Índice

Introdução	3
Visão Geral	4
Algoritmos Genéticos	5
Exemplo de utilização	6
Conclusão	8
Referências	9

1. Introdução

O fenômeno denominado Big Data tem impulsionado uma nova expansão na área da inteligência artificial. *Machine learning* é uma forma de implementar IA através de algoritmos que concedem a uma máquina a habilidade de tomar decisões. Este não é um assunto tão recente, técnicas de aprendizado de máquina já tem, nos últimos anos, revolucionado diversas áreas, desde a identificação de tumores através do processamento de imagens até sistemas de vigilância.

A teoria do controle automático, em contrapartida, já é extremamente consolidada e ainda contribui de maneira fundamental para o progresso tecnológico das últimas décadas. Seu impacto é considerável, atuando inclusive em sistemas sofisticados como aviões e satélites, tendo sido fundamental no sucesso do projeto Apollo, por exemplo. Entretanto, é amplamente reconhecido que o principal desafio para a aplicação de controle automático em inúmeras situações reais é a barreira computacional, o que limita muitas aplicações à utilização de um regulador quadrático linear. A busca por métodos numéricos para a teoria de controle já vem sendo feita há algum tempo, então é natural considerar a possibilidade da utilização de *machine learning*.

Assim, tem se observado, nos últimos anos, um esforço conjunto de profissionais de várias áreas para unir os dois temas citados anteriormente, o que garantiu diversas ideias interessantes e inovadoras. Um dos resultados, o *Machine Learning Control (MLC)*, é uma ramificação de aprendizado de máquina, controle inteligente e teoria de controle, cujo foco é resolver problemas de controle de sistemas dinâmicos utilizando métodos de *machine learning*, quando as técnicas usuais de controle linear não são suficientes.

2. Visão Geral

A figura 1 mostra um sistema de controle genérico. Nele é possível observar elementos familiares à teoria do controle clássico, como o controlador, sensores e distúrbios.

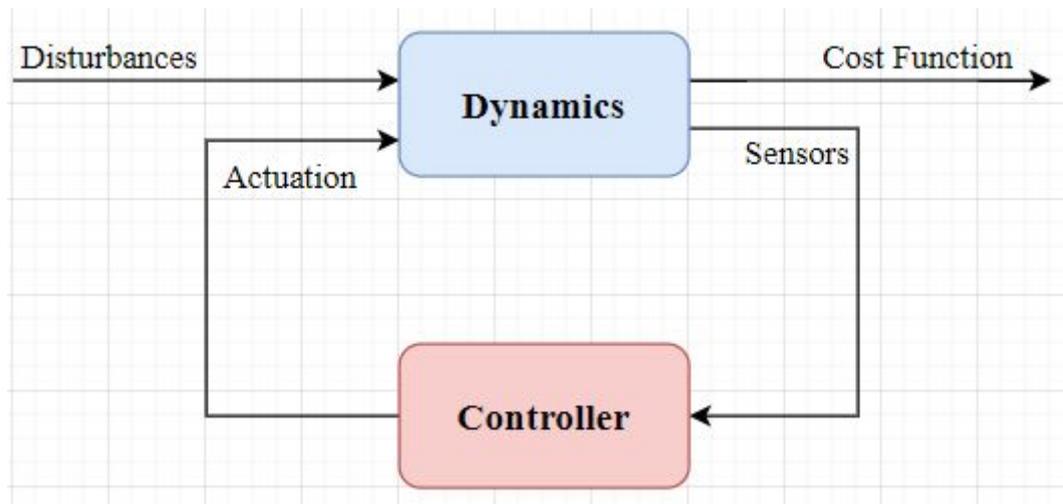


Figura 1 - Sistema de controle genérico.

A ideia a partir de agora é implementar técnicas *data-driven* tanto no sistema quanto no controlador. Por exemplo, *reinforcement learning* (aprendizado por reforço) é uma sub-área de aprendizado de máquina que estuda como utilizar dados passados para melhorar o comportamento futuro de um sistema dinâmico, ou seja, tem os mesmos objetivos que vários problemas de controle. Técnicas de RL tentam estimar modelos a partir de dados, o mesmo que a caracterização de sistemas em controle. Em seguida, pode-se aplicar programação dinâmica para derivar algoritmos comuns de *reinforcement learning*.

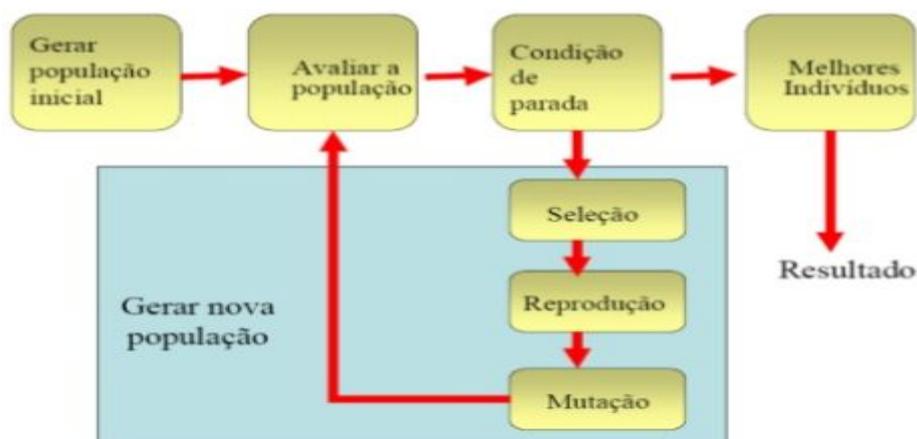
A programação dinâmica, porém, oferece um grande desafio computacional e numérico para sistemas complexos. Essa barreira pode ser transposta através da utilização de redes neurais, permitindo que o controlador seja continuamente atualizado com base em medidas de performance (reforço).

3. Algoritmos Genéticos

Algoritmo genético é um tipo de computação evolutiva, esses métodos são altamente inspirados no funcionamento biológico, evolução e adaptação de organismos vivos e comunidades biológicas. Os algoritmos genéticos se baseiam na ideia de código genético e reprodução, cada solução do problema é tratado como um indivíduo de uma população que inicialmente são criados aleatoriamente, as características dos indivíduos são parametrizadas e podem ser permutadas de forma semelhante aos genes dos seres vivos, o processo de propagação de uma característica é feita através de uma “reprodução” entre dois ou mais indivíduos, genericamente o processo de produção de uma nova população através da anterior se chama operadores genéticos, a permutação dos genes é somente um exemplo deles.

A reprodução utiliza dois ou mais indivíduos e permutam seus códigos genéticos para gerar um novo indivíduo com características semelhantes ao seus descendentes. A escolha de reprodução é feita baseada na teoria evolutiva de Darwin, os indivíduos são ranqueados de acordo com sua performance em resolver o problema e a probabilidade de reprodução é proporcional a essa medida de qualidade. Dessa forma, características vantajosas serão propagadas entre as gerações e as desvantajosas vão se perdendo. Isso é um processo iterativo e depois de várias gerações conseguimos uma solução com a performance desejada.

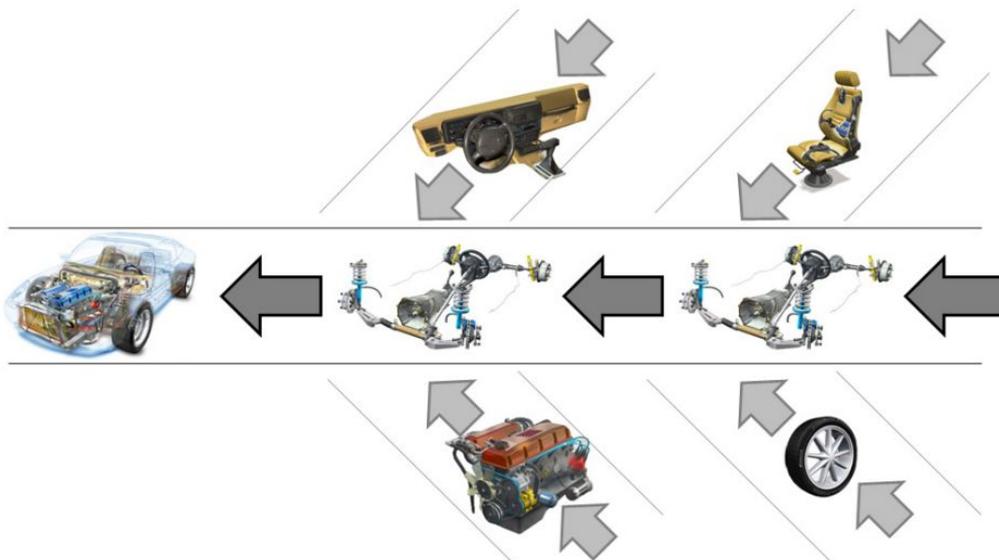
Uma outra característica importante desse método é a possibilidade da ocorrência de mutações, essas também são definidas dentre os operadores genéticos e funcionam como uma mudança aleatória de alguns indivíduos, essas mutações são importantes para que novas características apareçam dentro da população, porém não podem ser muito frequentes pois isso pode destruir a convergência da solução. Abaixo temos um diagrama que mostra o processo iterativo da evolução das populações:



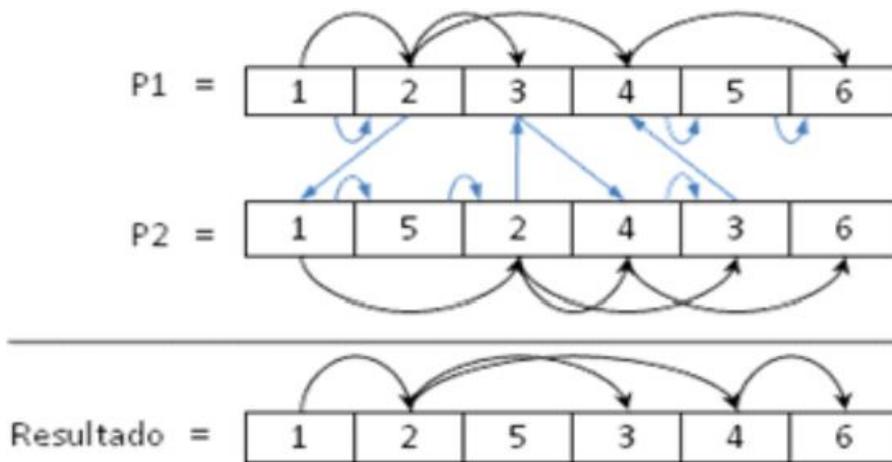
4. Exemplo de utilização

Vamos usar como exemplo dois casos dentro de um mesmo problema para exemplificar como podemos na prática utilizar esse método para resolver problemas de controle automático. Considere uma linha de produção onde um robô é responsável por decidir a sequência de etapas para montar determinado produto, vamos também considerar que em uma dessas etapas algum material deve passar por uma modelagem onde se deve controlar temperatura e pressão e um controlador deve ser usado para realizar essa tarefa.

Iniciando pela primeira parte do problema onde o robô tem que decidir uma sequência de etapas para conseguir a maior produção possível no menor tempo, iremos parametrizar cada uma das etapas por um código, esse código vai representar um “gene”, e a sequência dos passos na linha de produção formará nosso “código genético” de uma solução. Por ser uma linha de produção não precisamos executar cada um dos passos individualmente em uma sequência, podemos realizar o mesmo passo várias vezes em vários produtos e então passar para outro, ou seja, não é só um problema de permutação dos passos, é uma otimização. Abaixo temos uma imagem esquemática de uma linha de montagem onde podemos realizar as tarefas em ordens diferentes.



Para iniciar iremos criar a primeira população, formada com soluções aleatórias. Depois iremos testar cada uma dessas soluções e classificar cada uma delas pelo número de produtos terminados num período. Após isso temos que criar uma nova população a partir da primeira, utilizando os que tiverem melhores resultados podemos permutar sua sequência de genes para criar novas soluções, o tamanho dessa sequência também é determinada pelos ancestrais. Abaixo temos uma imagem que mostra um exemplo de reprodução de soluções, a lógica utilizada (linhas azuis) não foi explicada aqui, porém essa solução específica pode ser vista detalhada em [1].



Agora basta repetir esse processo até uma determinada condição de parada que pode ser uma produção mínima ou um número máximo de iterações. É importante observar que esse método é baseado na tentativa e erro, então na prática não podemos deixar uma linha de produção testar todos esses casos pois no começo a performance das soluções é muito baixa e também por que levaria muito tempo. Portanto, também seria necessário um simulador aproximado para que possamos analisar de forma mais eficiente, eventualmente com uma boa solução em mãos podemos passar para o teste real e continuar refinando o modelo.

Agora vamos analisar o problema onde as soluções de controle automático já estão bem consolidadas, controle de temperatura e pressão. Nessa parte vamos usar uma rede neural convencional onde teremos como input os dados de entrada e saída do sistema a ser controlado e como saída teremos a atuação do controlador no sistema, como um controlador convencional. O que iremos fazer de diferente é usar o método de algoritmos genéticos para treinar a nossa rede, isso vai permitir que nossa rede possa se adaptar a diferentes sistemas e diferentes perturbações através de uma seleção natural das soluções, o que não ocorreria normalmente em uma rede treinada para um sistema específico.

O procedimento é o mesmo usado anteriormente, porém agora os pesos e a própria topologia da rede serão os genes dos indivíduos. Isso vai permitir que possamos obter e analisar redes maiores ou menores de acordo com a resposta do sistema.

Em um problema normal de controle de temperatura e pressão a utilização de uma rede neural não se faz necessária, como já dito as soluções de controle automático serão mais rápidas e eficientes na maioria dos casos. Esse tipo de método só é recomendado quando temos um sistema que seja muito mais complexo que o controlador necessário para controlá-lo.

5. Conclusão

Algoritmos genéticos é um método que possui muito potencial na área de controle automático, seu poder de evolução e adaptação os torna ferramentas muito mais poderosas que técnicas convencionais, entretanto são técnicas muito custosas e dependente de várias tentativas ou simulações.

Improvável que *Machine Learning Control* irá substituir o controle automático já consolidado, eles são diferentes por natureza e podem o que decide qual será melhor é o sistema a ser controlado, técnicas de controle convencionais tem uma resposta determinística em relação a resposta do sistema em contrapartida a maioria das técnicas de machine learning, isso pode ser tanto uma vantagem como desvantagem. Em um sistema mais dinâmico que exige uma mudança do tipo de controlador será mais facilmente controlado por técnicas que permitem maior flexibilidade, enquanto sistemas menos dinâmicos serão mais facilmente controlados por controladores específicos.

6. Referências

[1] - RONALDO CRISTO, "Balanceamento de Linhas de Montagem com Uso de Algoritmo Genético para o Caso de Linhas Simples e Extensões"

<https://repositorio.ufsc.br/xmlui/handle/123456789/93714>

[2] - M. Nasiraghdam, S. Lotfi and R. Rashidy, "Query optimization in distributed database using hybrid evolutionary algorithm"

<https://ieeexplore.ieee.org/document/5466932>