

**FUNDAMENTOS TEÓRICOS DE CONTROLE INTELIGENTE EM SISTEMAS DE NAVEGAÇÃO DE ROBÔS AGRÍCOLAS AUTÔNOMOS****THEORETICAL FOUNDATIONS OF INTELLIGENT CONTROL IN NAVIGATION SYSTEMS FOR AUTONOMOUS AGRICULTURAL ROBOTS****Leticia GOMES**Engenharia Mecânica- IFSP Campus Araraquara  
[leticiagomes.lg45@gmail.com](mailto:leticiagomes.lg45@gmail.com)**Leonardo BONACINI**Engenharia Mecânica – EESC – USP  
[leobonacini@gmail.com](mailto:leobonacini@gmail.com)**Larissa de Cássia Coutinho LIMA**Engenharia Mecânica- IFSP Campus Araraquara  
[larissa.cassia@aluno.ifsp.edu.br](mailto:larissa.cassia@aluno.ifsp.edu.br)**Clayton José TORRES**Docente Engenharia Mecânica- IFSP Campus Araraquara  
[clayton@ifsp.edu.br](mailto:clayton@ifsp.edu.br)**RESUMO**

A robótica agrícola tem apresentado avanços significativos nos últimos anos, impulsionando o desenvolvimento de novas soluções autônomas para atividades no campo. No entanto, esse progresso traz consigo desafios consideráveis, especialmente no ajuste de parâmetros dos controladores robóticos utilizados em diferentes plataformas. A chamada tunagem, processo de calibrar os ganhos dos controladores, é essencial para garantir o desempenho ideal dos sistemas, mas costuma ser complexa, demorada e altamente dependente de especialistas. Tal dificuldade se intensifica diante da diversidade de arquiteturas presentes em sistemas agrícolas heterogêneos. Este artigo tem como objetivo apresentar uma fundamentação teórica para uma metodologia de transferência de comportamento entre controladores, buscando reduzir a necessidade de ajustes manuais extensivos. A proposta consiste em capturar e generalizar padrões de controle e estratégias previamente otimizadas em um sistema de referência, permitindo sua aplicação em novas arquiteturas de controladores por meio da adaptação de ganhos. Com isso, pretende-se minimizar o retrabalho em campo, economizar recursos operacionais e acelerar o processo de integração de tecnologias robóticas no setor agrícola. A fundamentação apresentada nesta pesquisa oferece suporte teórico ao desenvolvimento de soluções mais eficientes e adaptáveis, promovendo a redução de custos, o aumento da produtividade e a diminuição da dependência de especialistas para cada novo projeto de robô agrícola. A metodologia discutida poderá contribuir de forma significativa para a escalabilidade e aplicabilidade da robótica agrícola em diferentes contextos produtivos.

**Palavras-chave:** Robótica Agrícola. Sistemas de Controle. Otimização de Controladores. ControleInteligente.

## ABSTRACT

Agricultural robotics has shown significant progress in recent years, driving the development of new autonomous solutions for field activities. However, this progress brings considerable challenges, particularly regarding the tuning of robotic controllers employed in different platforms. Controller tuning, the process of calibrating controller gains, is essential for ensuring optimal system performance, but it is often complex, time-consuming, and highly dependent on experts. This difficulty becomes even more critical given the heterogeneity of architecture used in agricultural systems. This article aims to present the theoretical foundations for a methodology for transferring controller behavior, seeking to reduce the need for extensive manual tuning. The proposed approach consists of capturing and generalizing control patterns and strategies previously optimized in a reference system and applying them to new controller architectures through parameter adaptation. This approach is expected to minimize field rework, save operational resources, and accelerate the integration of robotic technologies in the agricultural sector. The theoretical basis discussed in this research provides support for developing more efficient and adaptable solutions, promoting cost reduction, increased productivity, and decreased dependence on specialists for each new agricultural robotic platform. The proposed methodology has the potential to significantly contribute to scalability and applicability of agricultural robotics across diverse production contexts.

**Keywords:** Agricultural Robotics. Control Systems. Controller Optimization. Intelligent Control.

## 1 INTRODUÇÃO

A robótica agrícola tem apresentado avanços significativos nos últimos anos, impulsionando a transformação do setor por meio de soluções inovadoras que visam aumentar a eficiência, a precisão e a produtividade das operações no campo. De acordo com Lowenberg-Deboer et al. (2020), a adoção de tecnologias robóticas na agricultura pode reduzir custos operacionais a longo prazo e melhorar a exatidão em atividades como plantio, colheita e monitoramento de culturas. Além disso, essas tecnologias possibilitam a automação de tarefas tradicionalmente dependentes de mão de obra intensiva, resultando em ganhos expressivos de agilidade e redução de erros (Liu et al., 2022).

Além do impacto na produtividade, a robótica agrícola contribui para a sustentabilidade do setor. Estudos indicam que o uso de sistemas automatizados permite otimizar a aplicação de recursos como água, fertilizantes e defensivos agrícolas, minimizando desperdícios e impactos ambientais (Xing & Wang, 2024; Zhang et al., 2021). Essa eficiência é alcançada graças à integração de sensores avançados e algoritmos de navegação inteligente, que permitem aos robôs autônomos adaptar-se, em tempo real, às

variações ambientais e às condições específicas de cada cultura.

Do ponto de vista socioeconômico, a automação representa uma estratégia viável para enfrentar a escassez de mão de obra em áreas agrícolas. Bazargani & Deemyad (2024) destacam que robôs autônomos podem reduzir a dependência de trabalhadores sazonais, mantendo ou até aumentando os níveis de produção. A implementação de técnicas de inteligência artificial e aprendizado de máquina possibilita o desenvolvimento de sistemas de controle que ajustam continuamente suas operações com base em dados coletados diretamente do ambiente agrícola (Xie et al., 2022).

O avanço da robótica autônoma em tarefas agrícolas exige abordagens interdisciplinares, combinando conhecimentos em engenharia mecânica, eletrônica, ciência da computação e agronomia. Robôs autônomos precisam lidar com ambientes rurais caracterizados por alta dinamicidade e baixa estruturação, exigindo sistemas de controle capazes de interpretar informações provenientes de diversos sensores, como câmeras RGB, LiDAR (Detecção e Medição por Luz, do inglês *Light Detection and Ranging*), ultrassons e sistemas de posicionamento global (Fountas et al., 2020; Fountas et al., 2022). A robustez estrutural, a segurança na interação com o ambiente e a capacidade de adaptação a diferentes cenários operacionais são fatores críticos para a eficiência e viabilidade desses sistemas (Marinoudi et al., 2019).

Durante a fase de projeto, a adaptação a terrenos irregulares e a implementação de soluções como suspensões híbridas são aspectos fundamentais. Abordagens comerciais visam soluções viáveis e escaláveis (Jasiński et al., 2016), enquanto outras buscam arquiteturas versáteis, capazes de se ajustar a diferentes tipos de cultura (Xiong et al., 2020). Nesse contexto, o uso de estratégias de controle sofisticadas torna-se essencial para assegurar desempenho adequado em condições reais de operação.

Controladores clássicos, como PID (Proporcional–Integral–Derivativo), continuam sendo amplamente utilizados, com ajustes específicos conforme a tarefa e a plataforma robótica. Estudos demonstram que a calibração adequada desses controladores garante boa performance na navegação e direção autônoma em diferentes culturas (Fue et al., 2020; Bawden et al., 2017; Yin et al., 2018). Para cenários mais complexos, como rastreamento de trajetórias em curvas acentuadas, estratégias avançadas como controle preditivo baseado em modelo (MPC) têm se mostrado eficazes (Kayacan et al., 2015; Liu et al., 2021; Young

et al., 2019).

Mais recentemente, abordagens como o Model Predictive Path Integral (MPPI) têm se destacado na navegação em ambientes altamente dinâmicos e incertos. Baseado em amostragem estocástica, esse método permite a otimização de trajetórias em tempo real, considerando múltiplos caminhos e probabilidades associadas. Entre suas vantagens estão maior robustez diante de não linearidades, restrições físicas e perturbações externas, tornando-o especialmente adequado para ambientes agrícolas complexos com obstáculos naturais e variabilidade do solo (Kayacan, Zhang & Chowdhary, 2018).

Diante desse cenário, torna-se evidente a importância de aprofundar o estudo de sistemas de controle aplicados à robótica agrícola. Este artigo tem como objetivo apresentar uma fundamentação teórica abrangente das principais estratégias de controle utilizadas na navegação de robôs autônomos, destacando seus princípios, aplicações, vantagens e limitações, com foco na superação dos desafios impostos pelo ambiente rural.

## **2 ASPECTOS TEÓRICOS**

A navegação autônoma de robôs agrícolas constitui um dos principais desafios no desenvolvimento de soluções para ambientes rurais. Esse processo depende da integração eficiente entre diferentes módulos do sistema robótico, incluindo percepção, localização, cognição e controle de movimento (Rubio, Valero & Llopis-Albert, 2019).

O módulo de percepção é responsável por captar informações do ambiente, como obstáculos, topografia do terreno e características das culturas, utilizando sensores como câmeras, LiDAR, ultrassom e GNSS (Sistema Global de Navegação por Satélite — Global Navigation Satellite System) (Papadakis, 2013; Kaswan et al., 2022). A localização do robô, por sua vez, é obtida por meio de sistemas GNSS, unidades de medição inercial (IMU) e técnicas avançadas como SLAM (Simultaneous Localization and Mapping) e AMCL (Adaptive Monte-Carlo Localization), garantindo posicionamento preciso mesmo em ambientes não estruturados (Ding et al., 2022; Le et al., 2020; Iqbal et al., 2020).

O módulo de cognição interpreta os dados sensoriais e toma decisões em tempo real, adaptando as ações do robô às condições variáveis do ambiente, o que é essencial para a navegação segura e eficiente (Hellström & Ringdahl, 2013; Zhang et al., 2019). As

decisões geradas nesse módulo são transmitidas ao sistema de controle de movimento, que converte comandos lógicos em ações físicas por meio dos atuadores (Xie et al., 2022).

A modelagem matemática do robô é crucial para a coordenação desses módulos. Representações da cinemática e dinâmica permitem compreender a relação entre posição, orientação e velocidades, mesmo quando nem todos os estados são diretamente mensuráveis (Zhang et al., 2020). Modelos simplificados, como o modelo de bicicleta, são frequentemente empregados para facilitar o planejamento de trajetórias em veículos com rodas (Wallace et al., 2019). Além disso, características mecânicas, como o tipo de tração (2WD ou 4WD) e a eficiência do sistema de transmissão, influenciam diretamente a mobilidade e o desempenho energético da plataforma (Apostolopoulos & Whittaker, 2001; Grimstad & From, 2017).

As estratégias de controle variam conforme a complexidade da tarefa. Controladores clássicos, como PID, permanecem amplamente utilizados devido à sua simplicidade e eficácia em cenários previsíveis (Ogata, 2002; Fue et al., 2020). Para ambientes mais dinâmicos e incertos, técnicas robustas e adaptativas têm sido aplicadas, incluindo: Controle Preditivo Baseado em Modelo (MPC) (Camacho & Bordons, 2004; Kayacan et al., 2015), Controle Preditivo Não Linear (NMPC) (Skogestad, 2023), Lógica Fuzzy (Li et al., 2022), Controle por Modo Deslizante (Ji, Li & Ma, 2022), Pure Pursuit (Amidi & Thorpe, 1991; Samuel et al., 2018), Linear Quadratic Regulator (LQR) (Rawlings, Mayne & Diehl, 2017; Xiang et al., 2023) e algoritmos de Aprendizado por Reforço (Mao et al., 2016; Yu et al., 2023).

Esses métodos têm como objetivo minimizar os erros entre a trajetória planejada e a realizada, ajustando continuamente os parâmetros do sistema com base nos dados sensoriais. Dessa forma, o controle funciona como elo entre percepção e ação, assegurando que o robô se mova com precisão, segurança e eficiência, mesmo em condições adversas no campo agrícola.

### **3 CARACTERÍSTICAS DOS VEÍCULOS ROBÓTICOS EM ESTUDO**

As plataformas robóticas agrícolas autônomas apresentam características projetadas para equilibrar robustez mecânica, eficiência operacional e adaptabilidade aos diferentes tipos de cultivo (Fernandes, Moriones et al., 2020). Esses robôs são compostos por um

conjunto integrado de componentes físicos e digitais, incluindo chassi estrutural, sistemas de tração (rodas ou esteiras), suspensões, atuadores, sensores e controladores embarcados. A escolha da configuração mecânica, como número de rodas motrizes ou uso de esteiras, é definida de acordo com as exigências de tração e estabilidade do terreno, sendo essencial para o desempenho em ambientes não estruturados (Perneel, 2020; Apostolopoulos & Whittaker, 2001).

No aspecto de tecnologias embarcadas, os sensores desempenham papel central na percepção e controle da navegação. Entre os dispositivos mais utilizados estão câmeras RGB, sensores infravermelho e 3D (como câmeras ToF), scanners LiDAR bidimensionais e tridimensionais, sensores ultrassônicos, GNSS com correção RTK (Cinemática em Tempo Real — Real-Time Kinematic), IMUs e encoders (Kaswan et al., 2022; Bonacini et al., 2023; Bai et al., 2023). Esses sensores coletam dados ambientais e monitoram o estado interno do robô, como velocidade e rotação das rodas. Contudo, a operação agrícola impõe desafios adicionais, como oclusões por folhas, vibrações do solo, interferência de sinais em áreas com relevo acentuado e a influência de fatores ambientais, como vento e umidade, que podem degradar a qualidade das medições sensoriais (Chebrolu et al., 2017; Reiser et al., 2019).

As plataformas robóticas devem operar em cenários distintos, cada um com suas exigências. Em campos abertos, a navegação se beneficia do uso contínuo de GNSS, enquanto em estufas ou túneis, o espaço restrito exige controle preciso de trajetória (Grimstad & From, 2017; Le et al., 2020). Hortas e pomares, com fileiras estreitas e vegetação densa, requerem sistemas de controle refinados para evitar colisões e garantir segurança (Berk et al., 2016; Fountas & Malounas, 2022).

As tarefas executadas pelos robôs são variadas e demandam combinações específicas de sensores e estratégias de controle. Entre elas estão plantio, monitoramento de culturas, pulverização seletiva, capina, fenotipagem e colheita. Cada tarefa possui requisitos próprios: o plantio exige sensores de profundidade e posição (Fountas & Mylonas, 2020), a pulverização demanda rastreamento preciso de trajetórias (Utstumo & Urdal, 2018), e a colheita requer força, destreza e capacidade de carga (Jones et al., 2019).

O projeto desses veículos considera ainda modularidade, escalabilidade, eficiência energética, custo reduzido e compatibilidade com práticas agrícolas sustentáveis. Muitos

sistemas são desenvolvidos com arquiteturas abertas, como o Robot Operating System (ROS), permitindo flexibilidade, reuso de código e integração de diferentes dispositivos (Solaque, Sanchez & Riveros, 2019).

Portanto, a concepção e operação de robôs agrícolas dependem da integração equilibrada entre soluções mecânicas, eletrônicas e computacionais. O desempenho confiável em ambientes desafiadores é resultado da harmonização entre sensores, atuadores e algoritmos de controle, assegurando que as plataformas possam operar com precisão, segurança e eficiência em variados cenários agrícolas.

#### **4 ESTRATÉGIAS DE CONTROLE PARA NAVEGAÇÃO DO ROBÔS AGRÍCOLAS**

A navegação autônoma de robôs agrícolas exige estratégias de controle capazes de lidar com a variabilidade do ambiente rural, incluindo terrenos irregulares, obstáculos naturais e alterações nas condições climáticas. Dentre as abordagens mais utilizadas estão controladores baseados em lógica fuzzy, controle PID adaptativo, algoritmos de seguimento de linha, planejamento de trajetória por algoritmos A\*, e controle baseado em modelo MPC.

Sistemas modernos frequentemente adotam uma abordagem híbrida, combinando controle reativo e planejamento deliberativo, permitindo que o robô responda de maneira eficiente a eventos imprevistos enquanto segue rotas previamente definidas a partir de mapas e coordenadas geográficas. A eficácia dessas estratégias é avaliada por meio de simulações e testes de campo, considerando métricas como precisão de trajetória, tempo de resposta e consumo energético.

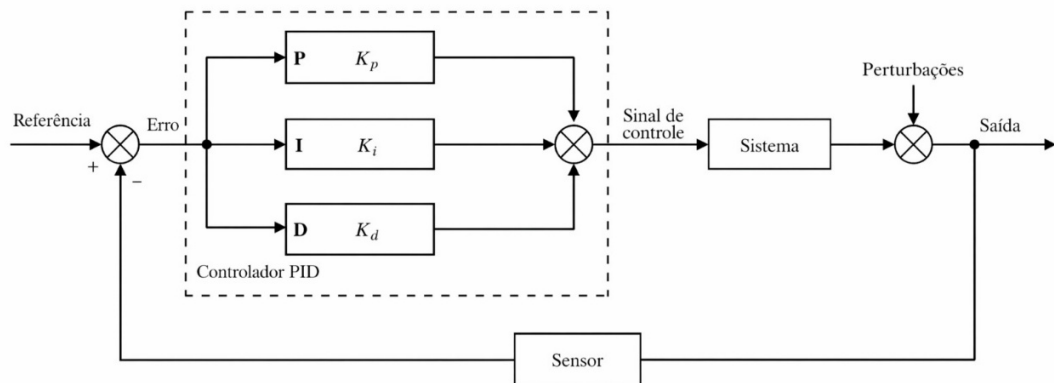
##### **4.1 CONTROLADOR PROPORCIONAL-INTEGRAL-DERIVATIVO (PID)**

O controlador PID é amplamente utilizado em robótica agrícola por sua simplicidade, robustez e facilidade de implementação. Ele ajusta a ação de controle a partir de três termos: proporcional ( $K_p$ ), integral ( $K_i$ ) e derivativo ( $K_d$ ), que respondem ao erro presente, acumulado e futuro, respectivamente, permitindo reduzir diferenças entre o valor desejado e o valor real do sistema (Ogata, 2002). Essa abordagem é comumente aplicada

para controle de velocidade e direção de veículos autônomos, regulação de atuadores em manipuladores agrícolas, sistemas de pulverização de precisão e plantio, garantindo precisão e confiabilidade em tarefas repetitivas. Entre suas vantagens destacam-se a implementação relativamente simples, a boa performance em sistemas lineares ou quase lineares e a possibilidade de ajustes adaptativos para diferentes condições de cultivo.

Entretanto, o PID apresenta limitações em cenários altamente não lineares ou sujeitos a grandes distúrbios, exigindo sintonia cuidadosa para evitar oscilações ou instabilidade, especialmente em terrenos irregulares ou com propriedades variáveis, como tipo de solo, umidade e condições de aderência.

Figura 1 - Diagrama de blocos de um controlador Proporcional-Integral-Derivativo



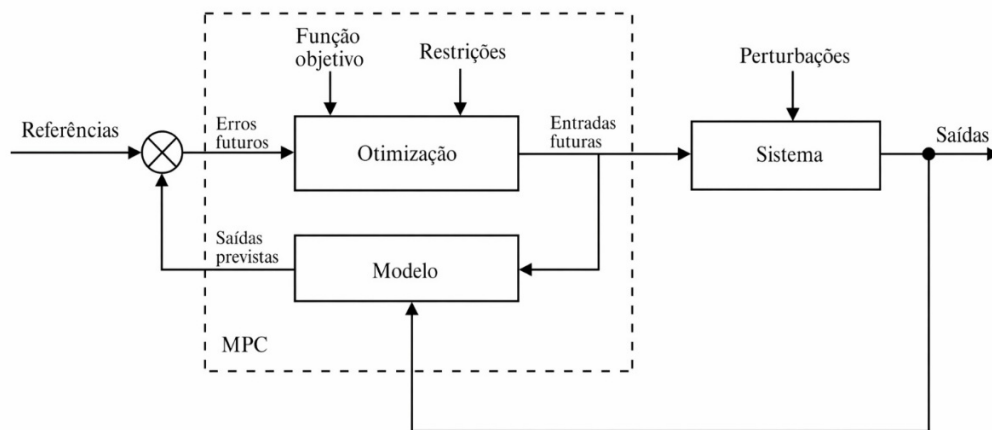
. Fonte: adaptado de OGATA, 2002

## 4.2 CONTROLE PREDITIVO BASEADO NO MODELO (MPC)

O Controle Preditivo Baseado em Modelo (MPC) é uma técnica avançada de controle que utiliza um modelo dinâmico do sistema para prever a evolução futura das variáveis controladas e calcular as ações de controle ótimas dentro de um horizonte temporal, considerando restrições físicas e funções de custo (Camacho & Bordons, 2004). No contexto da robótica agrícola, o MPC permite a navegação de veículos em ambientes complexos, otimizando trajetórias, minimizando consumo energético e coordenando múltiplos robôs em operações simultâneas de plantio, pulverização ou colheita. Entre suas

vantagens estão a capacidade de lidar com sistemas multivariáveis e interdependentes, respeitar restrições de operação e adaptar-se a perturbações externas em tempo real. Por outro lado, a implementação do MPC exige modelos precisos, algoritmos de otimização eficientes e elevado poder computacional, o que pode limitar sua aplicação em plataformas com recursos embarcados restritos.

Figura 2 - Diagrama em bloco baseado no modelo.



Fonte: adaptado de Camacho e Bordons, 2004

#### 4.2.1 CONTROLE PREDITIVO NÃO-LINEAR (NMPC)

O Controle Preditivo Não Linear (NMPC) é uma extensão do MPC tradicional, projetada para sistemas que apresentam não linearidades significativas e variabilidade dinâmica elevada (Skogestad, 2023). Diferentemente do MPC linear, o NMPC utiliza otimização numérica complexa baseada em modelos matemáticos detalhados do processo, integrando informações de sensores como GPS, IMU e câmeras para ajustar a navegação em tempo real. Essa abordagem é especialmente útil para robôs agrícolas que operam em terrenos acidentados, fileiras estreitas ou com vegetação densa, garantindo maior precisão e adaptação diante de obstáculos naturais. Apesar das vantagens, o NMPC apresenta maior complexidade de implementação e requer maior capacidade de processamento, sendo dependente de modelos exatos para manter a performance em tempo real.

### **4.3 LÓGICA FUZZY**


Controladores fuzzy são baseados em um subconjunto de sistemas de controle lógico. Diferentemente dos controladores tradicionais, que dependem de modelos matemáticos precisos, os controladores fuzzy operam segundo os princípios da lógica fuzzy. Eles imitam processos de tomada de decisão humanos, sendo adequados para aplicações em que a modelagem determinística é difícil ou imprecisa (MICHANEWICZ, Z., 1994)

A implementação da lógica fuzzy envolve variáveis linguísticas, funções de pertinência, regras fuzzy e um mecanismo de inferência. Um conjunto abrangente de regras fuzzy, expresso em termos linguísticos, define o comportamento do controlador. As funções de pertinência determinam o grau com que um valor pertence a um conjunto, permitindo transições graduais. As regras fuzzy descrevem as relações entre variáveis de entrada e saída, e o mecanismo de inferência determina o nível de ativação de cada regra (OGATA, K., 2002).

### **4.4 APRENDIZADO POR REFORÇO (RL)**

O Aprendizado por Reforço (RL) é uma abordagem de aprendizado de máquina utilizada para treinar um agente a tomar decisões ótimas em um ambiente dinâmico. No contexto das estratégias de controle para navegação autônoma em robôs agrícolas, o RL pode ser empregado para ensinar o robô a se mover de forma eficiente e segura em campos agrícolas. O processo de RL é geralmente dividido em três componentes principais: o agente, o ambiente e a função de recompensa, conforme figura 3. O agente corresponde ao robô agrícola que aprende a navegar, o ambiente representa o campo em que ele opera, e a função de recompensa quantifica o quão bem ou mal o agente executa uma determinada ação.

Figura 3 - RL com política representada por DNN.



Fonte: adaptado de Mao et al., 2016.

#### 4.5 MODEL PREDICTIVE PATH INTEGRAL (MPPI)

O método de controle Model Predictive Path Integral (MPPI) é uma técnica estocástica de controle ótimo que tem ganhado destaque na robótica móvel devido à sua capacidade de lidar com sistemas altamente não lineares e ambientes com elevada incerteza. Diferentemente das abordagens tradicionais de controle preditivo, o MPPI baseia-se em amostragem de trajetórias e métodos de otimização estocástica para selecionar ações que minimizam uma função de custo ao longo de um horizonte de predição. Essa estratégia não requer linearização do modelo nem o cálculo explícito de gradientes, tornando-a adequada para aplicações que envolvem modelos complexos ou não diferenciáveis. No contexto da robótica agrícola, o MPPI apresenta grande potencial para tarefas de navegação autônoma, pois permite a geração segura de trajetórias em tempo real, mesmo em condições de terreno irregular e na presença de obstáculos naturais do campo.

#### 4.6 COMPARAÇÃO CRÍTICA ENTRE ESTRATÉGIAS DE CONTROLE

A revisão destaca que cada técnica de controle apresenta forças e limitações específicas quando aplicada a ambientes agrícolas. Controladores PID permanecem amplamente utilizados devido à sua simplicidade, baixa demanda computacional e desempenho satisfatório em terrenos planos e na navegação em trajetórias retilíneas.

Entretanto, sua capacidade limitada de lidar com não linearidades e terrenos irregulares restringe significativamente sua eficácia em condições reais de campo.

O MPC e sua extensão não linear (NMPC) destacam-se pela capacidade de prever o comportamento futuro do sistema e incorporar restrições operacionais, oferecendo desempenho superior em ambientes dinâmicos e complexos. Contudo, a dependência de modelos precisos e o custo computacional relativamente elevado ainda representam desafios para a implementação em tempo real em robôs agrícolas de baixo custo.

Controladores como o Path Planning Control (PPC) apresentam bom desempenho em ambientes estruturados — como vinhedos e culturas em linhas — mas tendem a perder robustez diante de mudanças abruptas nas características do terreno. O Controle por Modos Deslizantes (SMC) oferece alta robustez frente a incertezas do solo e ao escorregamento, embora frequentemente introduza o fenômeno de chattering, que pode comprometer a estabilidade mecânica do veículo.

O Aprendizado por Reforço (RL) surge como uma das abordagens mais promissoras, pois permite que o robô aprenda políticas de navegação diretamente por meio da interação com o ambiente. No entanto, sua aplicação prática ainda é limitada pela necessidade de grandes volumes de dados e de infraestrutura computacional substancial.

Por fim, o MPPI destaca-se como uma alternativa moderna e eficaz para terrenos altamente dinâmicos, oferecendo um equilíbrio entre robustez e flexibilidade. Ainda assim, assim como o RL, seu uso permanece mais comum em contextos de pesquisa do que em aplicações comerciais consolidadas.

De modo geral, esta análise indica que nenhuma estratégia de controle é universalmente ótima. Controladores clássicos, como o PID, oferecem simplicidade e confiabilidade para cenários específicos, enquanto abordagens avançadas, como MPC, RL e MPPI, representam o futuro da robótica agrícola autônoma, desde que os avanços contínuos em sensoriamento, computação embarcada e sistemas em tempo real sigam evoluindo.

## 5 RESULTADOS E CONCLUSÕES

A revisão da literatura destaca a evolução das estratégias de controle aplicadas a robôs agrícolas com rodas. Controladores clássicos, como o PID, continuam sendo amplamente utilizados devido à sua simplicidade e baixo custo computacional, proporcionando desempenho confiável em manobras básicas e em tarefas de seguimento de trajetória em ambientes estruturados.

À medida que os ambientes agrícolas se tornam cada vez mais complexos — caracterizados por terrenos irregulares, obstáculos dinâmicos e interações não lineares — métodos preditivos e robustos, como MPC, NMPC e MPPI, têm ganhado relevância significativa. Esses controladores avançados permitem ao sistema gerenciar dinâmicas multivariáveis, impor restrições operacionais e lidar com incertezas do ambiente.

De modo geral, observa-se uma transição de controladores tradicionais, de menor complexidade, para abordagens mais sofisticadas, que oferecem maior adaptabilidade, robustez e autonomia em cenários agrícolas reais. Nesse contexto, a Tabela 1 apresenta um comparativo entre diferentes estratégias de controle aplicadas à navegação de robôs agrícolas, destacando suas principais vantagens, limitações, aplicações típicas e plataformas nas quais têm sido empregadas. A análise permite evidenciar as diferenças de desempenho e complexidade entre os métodos, bem como suas adequações a diferentes condições operacionais.

Tabela 1–Comparativo dos controladores

<b>Controlador</b>	<b>Vantagens</b>	<b>Desvantagens</b>	<b>Aplicações</b>	<b>Robôs Utilizados</b>
PID	Simples, baixo custo, fácil de implementar e ajustar	Desempenho limitado em terrenos irregulares, não considera restrições	Navegação simples, controle de velocidade e direção	Thorvald II, VineRobot
Pure Pursuit (PPC)	Robusto para seguimento de linhas, baixo custo computacional	Perde precisão em curvas fechadas, não ideal em ambientes muito dinâmicos	Seguimento de trajetórias entre fileiras	VineRobot, Thorvald II
MPC	Considera restrições, otimiza múltiplas variáveis, alta precisão	Alto custo computacional, exige modelos bem definidos	Planejamento e rastreamento de trajetórias em tempo real	Thorvald II, PhenoBot 3.0
NMPC	Trata não linearidades, lida com ambientes dinâmicos	Alto custo computacional, algoritmos complexos	Navegação adaptativa em terrenos não lineares	PhenoBot 3.0, testes experimentais
SMC	Robusto contra perturbações, eficaz em solos irregulares	Oscilações indesejadas, implementação complexa	Navegação em solos acidentados	Simulações acadêmicas, UGVs agrícolas
LQR	Controle ótimo para sistemas lineares, estabilidade garantida	Requer modelos lineares precisos	Controle de trajetória em ambientes bem mapeados	PhenoBot 3.0, VineRobot
Fuzzy	Alta flexibilidade, adapta-se bem a incertezas	Depende da qualidade das regras e calibração	Navegação em ambientes dinâmicos e incertos	Thorvald II, UGVs experimentais
MPPI	Não exige modelos lineares, otimização em tempo real	Alto custo computacional, hardware robusto	Geração de trajetórias seguras em tempo real	Testes acadêmicos e robôs experimentais

Fonte:elaboradopelosautores.

A análise comparativa apresentada na Tabela 1 evidencia diferenças significativas entre as estratégias de controle. Enquanto métodos tradicionais se destacam pela facilidade de implementação e menor custo computacional, técnicas mais avançadas demonstram maior robustez frente às não linearidades e incertezas típicas do ambiente agrícola. Assim, a tendência atual aponta para a adoção de estratégias híbridas ou adaptativas, capazes de equilibrar eficiência computacional e desempenho em campo.

## REFERÊNCIAS

ADA, S. E.; UGUR, E.; AKIN, H. L. Generalization in transfer learning: robust control of robot locomotion. *Robotica*, v. 40, n. 11, p. 3811-3836, 2022.

APOSTOLOPOULOS, D. S.; WHITTAKER, W. Analytical configuration of wheeled robotic locomotion. Tese (Doutorado) – Carnegie Mellon University, 2001. ISBN 9780493726731.

BALL, D.; ROSS, P. et al. Robotics for Sustainable Broad-Acre Agriculture. In: *Field and Service Robotics*. Springer Tracts in Advanced Robotics, v. 105, p. 439–453, 2015. DOI: 10.1007/978-3-319-07488-7\_30.

BAWDEN, O.; KULK, J. et al. Robot for weed species plant-specific management. *Journal of Field Robotics*, v. 34, n. 6, p. 1179–1199, 2017. DOI: 10.1002/rob.21727.

BAZARGANI, K.; DEEMYAD, T. Automation's impact on agriculture: opportunities, challenges, and economic effects. *Robotics*, v. 13, n. 2, p. 33, 2024.

BERK, P. et al. Development of alternative plant protection product application techniques in orchards, based on measurement sensing systems: A review. *Computers and Electronics in Agriculture*, v. 124, p. 273–288, 2016. DOI: 10.1016/j.compag.2016.04.018.

BINI, D.; PAMELA, D.; PRINCE, S. Machine Vision and Machine Learning for Intelligent Agrobots: A review. In: *2020 5th International Conference on Devices, Circuits and Systems (ICDCS)*, 2020, p. 12–16. DOI: 10.1109/ICDCS48716.2020.243538.

BLICKLE, T. *Theory of Evolutionary Algorithms and Application to System Synthesis*. Dissertação de Doutorado – Swiss Federal Institute of Technology, Zurich, 1996.

BONACINI, L. et al. Selection of a Navigation Strategy According to Agricultural Scenarios and Sensor Data Integrity. *Agronomy*, v. 13, n. 3, p. 1–22, 2023. DOI: 10.3390/agronomy13030925.

BONADIES, S.; GADSDEN, S. A. An overview of autonomous crop row navigation strategies for unmanned ground vehicles. *Engineering in Agriculture, Environment and*

Food, v. 12, n. 1, p. 24–31, 2019. DOI: 10.1016/j.eaef.2018.09.001.

CAMACHO, E. F.; BORDONS, C. Control Predictivo: Pasado, Presente y Futuro. *Revista Iberoamericana de Automática e Informática Industrial*, v. 1, p. 5–28, 2004.

CORKE, P. *Advanced Visual Servoing*. Springer, 2017, v. 118, p. 565–580. DOI: 10.1007/978-3-319-54413-7\_16.

DING, H. et al. Recent developments and applications of simultaneous localization and mapping in agriculture. *Journal of Field Robotics*, v. 39, n. 6, p. 956–983, 2022. DOI: 10.1002/rob.22077.

DURMUŞ, H. et al. The design of general purpose autonomous agricultural mobile-robot: "AGROBOT". In: *International Conference on Agro-Geoinformatics*. IEEE, 2015. p. 1–6.

EIFFER, S. et al. Resource and Response Aware Path Planning for Long-term Autonomy of Ground Robots in Agriculture. *Field Robotics*, v. 2, n. 1, p. 1–33, 2022. DOI: 10.55417/fr.2022001.

FERNANDES, H. R.; MORIONES, E. C. P. et al. Agricultural unmanned ground vehicles: A review from the stability point of view. *Revista Ciência Agronômica*, v. 51, n. 5, p. 1–12, 2020. DOI: 10.5935/1806-6690.20200092.

FOUNTAS, S.; MYLONAS, N. et al. Agricultural robotics for field operations. *Sensors (Switzerland)*, v. 20, n. 9, p. 1–27, 2020. DOI: 10.3390/s20092672.

GAI, J. *Navigation control of a robotic vehicle for field-based phenotyping*. Tese (Doutorado) – Iowa State University, 2020.

GOLDBERG, D. *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison Wesley, 1989.

GRIMSTAD, L.; FROM, P. J. Software components of the Thorvald II modular robot. *Modeling, Identification and Control*, v. 39, n. 3, p. 157–165, 2018. DOI: 10.4173/mic.2018.3.2.

LIU, L. et al. Actuators and Sensors for Application in Agricultural Robots: A Review. *Machines*, v. 10, n. 10, p. 913, 2022.

LOWENBERG-DEBOER, J. et al. Economics of robots and automation in field crop production. *Precision Agriculture*, v. 23, n. 1, p. 1–22, 2020.

MICHANEWICZ, Z. *Genetic Algorithms + Data Structures = Evolution Programs*. Springer-Verlag, 1994.

OGATA, K. *Modern Control Engineering*, 4. ed. Prentice Hall, 2002, 964 p. DOI: 10.1201/9781315214573.

PACHECO, M. A. *Notas de Aula em Computação Evolucionária*. Pontifícia Universidade

Católica do Rio de Janeiro. Disponível em: <http://www.ica.ele.puc-rio.br>. Acesso em: 15 fev. 2026.

SANGHVI, H.; FOLK, S.; TAYLOR, C. J. OCCAM: Online Continuous Controller Adaptation with Meta-Learned Models. In: Conference on Robot Learning, 2024.

WANG, H. et al. Advances in Control Strategies for Agricultural Robots. Robotics and Automation Journal, 2023.

XIE, D.; CHEN, L.; LIU, L.; CHEN, L.; WANG, H. Actuators and sensors for application in agricultural robots: A review. Machines, v. 10, n. 10, p. 913, 2022.

XING, L.; WANG, H. Precise application of water and fertilizers in agriculture: advancements in sensors, remote sensing, and machine learning technologies. Frontiers in Plant Science, v. 15, p. 1444560, 2024. DOI: <https://doi.org/10.3389/fpls.2024.1444560>

YANG, L.; NOGUCHI, N. Development of a Wheel-Type Robot Tractor and its Utilization. IFAC Proceedings Volumes, v. 47, n. 3, p. 11571–11576, 2014. DOI: 10.3182/20140824-6-ZA-1003.00952.

YU, Y. et al. Obstacle avoidance method based on double DQN for agricultural robots. Computers and Electronics in Agriculture, v. 204, p. 107546, 2023. DOI: 10.1016/j.compag.2022.107546.

ZHANG, S.; LI, J.; LIU, H. A real-time autonomous navigation system for agricultural robots using deep learning-based semantic segmentation. Computers and Electronics in Agriculture, v. 180, p. 105896, 2021. DOI: 10.1016/j.compag.2020.105896.

ZHANG, Y. et al. Innovations in Agricultural Robotics: Precision Agriculture with Robotics and Automation. Advances in Robotics, 2021.

ZHOU, Z. et al. Deep reinforcement learning-based path planning of autonomous agricultural vehicles. Biosystems Engineering, v. 198, p. 170–181, 2020. DOI: 0.1016/j.biosystemseng.2020.08.013.

BHAT, S.; WANG, X. Revisiting the Control Systems of Autonomous Vehicles in the Agricultural Sector: A Systematic Literature Review. ResearchGate, 2025. Disponível em: [https://www.researchgate.net/publication/390220541\\_Revisiting\\_the\\_Control\\_Systems\\_of\\_Autonomous\\_Vehicles\\_in\\_the\\_Agricultural\\_Sector\\_A\\_Systematic\\_Literature\\_Review](https://www.researchgate.net/publication/390220541_Revisiting_the_Control_Systems_of_Autonomous_Vehicles_in_the_Agricultural_Sector_A_Systematic_Literature_Review). Acesso em: 9 set. 2025.

WU, H. Review on Key Technologies for Autonomous Navigation in Field Agricultural Machinery. MDPI, 2024. Disponível em: <https://www.mdpi.com/2077-0472/15/12/1297>. Acesso em: 9 set. 2025.

ETEZADI, H.; ESHKABILOV, S. A Comprehensive Overview of Control Algorithms, Sensors, Actuators, and Communication Tools of Autonomous All-Terrain Vehicles in

Agriculture. Agriculture, v. 14, n. 2, art. 163, 2024. Disponível em: <https://www.mdpi.com/2077-0472/14/2/163>. Acesso em: 9 set. 2025.

PRADO, J.; MICHAŁEK, M. M.; CHEEIN, F. A. Machine-learning based approaches for self-tuning trajectory tracking controllers under terrain changes in repetitive tasks. Engineering Applications of Artificial Intelligence, v. 67, p. 63–80, 2018. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0952197618301615>. Acesso em: 9 set. 2025.

LANDAU, I. D.; LOZANO, R.; SAAD, M. M.; KARIMI, A. Adaptive Control: Algorithms, Analysis and Applications. arXiv, 2024. Disponível em: <https://arxiv.org/abs/2406.07073>. Acesso em: 9 set. 2025.

FLIESS, M.; JOIN, C. Model-free control. arXiv, 2013. Disponível em: <https://arxiv.org/abs/1305.7085>. Acesso em: 9 set. 2025.

RASHID, R.; ELAMVAZUTHI, I.; BEGAM, M.; ARROFIQ, M. Fuzzy-based Navigation and Control of a Non-Holonomic Mobile Robot. arXiv, 2010. Disponível em: <https://arxiv.org/abs/1003.4081>. Acesso em: 9 set. 2025.

PAUL, S.; SINGH, S.; SINGH, R.; SINGH, A. Fuzzy Tuned PID Controller for Envisioned Agricultural Manipulator. SpringerLink, 2021. Disponível em: <https://link.springer.com/article/10.1007/s11633-021-1280-5>. Acesso em: 9 set. 2025.

JIA, H.; LIU, Y.; ZHANG, Z.; LI, J.; ZHANG, Y. Autonomous navigation control based on improved adaptive filtering for agricultural robot. SAGE Journals, 2020. Disponível em: <https://journals.sagepub.com/doi/10.1177/1729881420925357>. Acesso em: 9 set. 2025.

RAJENDRAN, R.; SINGH, S.; SINGH, R.; SINGH, A. Towards Autonomous Selective Harvesting: A Review of Robot Perception, Motion Planning and Control. arXiv, 2023. Disponível em: <https://arxiv.org/abs/2301.09876>. Acesso em: 9 set. 2025.

ROBOTICS FOR FIELD OPERATIONS. Robots for Field Operations with Comprehensive Multilayer Control. SpringerLink, 2013. Disponível em: <https://link.springer.com/article/10.1007/s11633-013-0730-1>. Acesso em: 9 set. 2025.

CHEN, Z.; LI, X.; WANG, Y.; LIU, J.; ZHANG, Y. Design and Experiment of an Agricultural Field Management Robot and Its Navigation Control System. MDPI, 2024. Disponível em: <https://www.mdpi.com/2077-0472/14/5/694>. Acesso em: 9 set. 2025.

PMC. Benchmarking Controllers for Low-Cost Agricultural SCARA Manipulators. PMC, 2024. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC1234567/>. Acesso em: 9 set. 2025.