

## 4 Modelagem do jogador

Essa técnica também é conhecida como modelagem de adversários ou oponentes, como usada por alguns autores (Herik05, Bakkes09). Baseada no conceito de modelagem de estudantes usado em sistemas adaptativos educativos (Houlette04, p. 557), onde o programa de ensino detecta características do estudante para melhor direcionar seus estudos, a definição de Cowley et al. para *player modeling* é:

“[...] uma técnica para inferir atributos de alta-ordem do jogador usando uma larga quantidade de informações de dados de tipos primitivos do jogador e descrevê-lo a outros processos usando algum algoritmo de classificação”. (Cowley08, tradução nossa).

Cowley et al. (Cowley08) identificam que, durante uma sessão de jogo, o jogador é definido por informações pessoais e/ou dados do *log* de jogo, podendo ser modelado com construtos tipológicos (em relação às informações pessoais obtidas pelo jogo) e/ou construtos de modelagem (em relação aos dados da sessão de jogo). Informações com relevância semântica para a modelagem de jogador incluiriam dados de entrada e saída do jogo, como velocidade de reflexo do jogador, taxa de acertos, posicionamento em relação a oponentes e a média de repetições em uma fase, ou também dados externos, como classificação tipológica psicológica segundo algum modelo como o de Bartle (Bartle96) ou o modelo estendido de Stewart (Stewart11).

Tais informações coletadas do jogador podem ser usadas para adaptar a inteligência artificial do jogo ao jogador (Houlette04, p. 557), convertidas em características pertencentes a uma modelagem. Dependendo da perspectiva utilizada para verificar e classificar essas informações, elas podem servir como uma medida do conhecimento e habilidade do jogador ou como um indicador de seus hábitos e preferências, o que modifica a construção da modelagem, embora as diferenças entre uma e outra possam ser sutis. A complexidade do modelo em ser projetado, analisado e atualizado está diretamente relacionada à quantidade de detalhes do modelo, embora uma modelagem mais detalhada possa fornecer informações mais relevantes sobre o comportamento do jogador.

Tabela 4.1: Taxonomia de modelagem de jogador segundo Machado et al. (Machado11a)

Descrição	Categorias	Objetivos
Conhecimento	Rastreamento <i>online</i>	Colaboração
Posição	Reconhecimento <i>online</i> de estratégia	Adversarial
Estratégia	Revisão <i>offline</i>	Narrativa
Satisfação		Substituição
Aplicações	Métodos	Implementação
Especação em busca	Modelagem de ação	Explícita
Tutorial	Modelagem de pre-ferências	Implícita
Treinamento	Modelagem de posição Modelagem de conhecimento	

Pesquisas em modelagem de jogador incluem os trabalhos de Charles et al. em um *framework* de modelagem de jogador (Charles04, Charles05), o uso de aprendizado supervisionado para modelagem e ajuste dinâmico de dificuldade de Missura e Gärtner (Missura09) e o uso de redes bayesianas para geração de modelos e a avaliação do interesse dos jogadores por Yannakakis e Maragoudakis (Yannakakis05).

## 4.1 Taxonomias de modelagem de jogador

Nesta seção, apresentamos duas taxonomias propostas para modelagem de jogador: a proposta de Machado et al. (Machado11a) e a proposta de Smith et al. (Smith11).

### 4.1.1 Taxonomia de Machado et al.

Na taxonomia de Machado et al. (Machado11a), a modelagem de jogador pode ser classificada segundo seis fatores, resumidos na Tabela 4.1: tipo de descrição do jogador, categoria de uso da modelagem, objetivo da modelagem, aplicação da modelagem, método de modelagem e implementação da modelagem.

Quanto à descrição do jogador, a modelagem pode ser classificada: quanto ao conhecimento do jogador dentro do jogo (e.g. o quanto do mapa de jogo foi explorado); quanto ao posicionamento do jogador no mundo de jogo; quanto à satisfação do jogador em jogar (i. e. suas preferências de jogo); e quanto às estratégias que usa.

Quanto às categorias de uso, pode ser classificada: como rastreamento *online*, quando a preocupação é com as ações futuras imediatas do jogador; como reconhecimento *online* de estratégia quando envolve identificar um conjunto de ações como estratégias; e como revisão *offline* quando usa dados de fora da experiência de jogo, como *logs* de partidas anteriores.

Quanto aos objetivos, pode ser classificada como: colaborativa, quando o objetivo é gerar agentes que auxiliem o jogador; adversarial, quando o objetivo é gerar oponentes adaptados ao jogador; narrativa, quando o objetivo é ajudar na criação, manutenção ou avanço de uma linha narrativa (e.g. reações e emoções de NPCs).

Quanto à aplicação, pode ser classificada como: especulação em busca, quando a modelagem pode ser usada para auxiliar heurísticas de busca (e.g. poda  $\alpha$ - $\beta$ ); tutorial, quando o uso da modelagem é voltado ao ensino do jogador por um agente inteligente; treinamento, quando o agente inteligente usa a modelagem para selecionar desafios voltados às características do jogador; substituição, quando o agente inteligente é usado para substituir um jogador humano (e.g. em *Left 4 Dead* (Valve08), quando não há jogadores suficientes para completar a equipe ou quando um dos jogadores perde a conexão).

Quanto ao método de modelagem, pode ser classificada como: modelagem de ação, quando a modelagem é feita sobre as ações do jogador, em uma tentativa de prever as ações seguintes; modelagem de preferência, quando a modelagem se refere aos objetivos do jogador com o jogo (o que ele pretende durante aquela experiência de jogo); modelagem de posicionamento, quando a modelagem usa informações de posições previamente conhecidas do jogador para articular uma estratégia (e.g. em jogos de estratégia para simular a ‘neblina de guerra’); modelagem de conhecimento, quando a modelagem é usada para inferir o conhecimento do jogador.

Quanto à implementação da modelagem, ela pode ser classificada como: explícita, quando o modelo de jogador existe em separado de sua representação em código dentro do jogo (e.g. através de *scripts* externos); implícita, quando as informações do modelo do jogador estão diluídas pela representação em código, sem se encontrar separadas e já computadas.

#### 4.1.2

##### **Taxonomia inclusiva de Smith et al.**

A modelagem de jogador nesta taxonomia é dividida em quatro facetas: o escopo de aplicação; o propósito do uso; o domínio das características modeladas; e a fonte da derivação do modelo ou da motivação. A Tabela 4.2 sintetiza as classificações possíveis por faceta.

Tabela 4.2: Taxonomia inclusiva de Smith et al. (Smith11)

Escopo	Propósito	Domínio	Fonte
Individual	Geradora	Ações de jogo	Induzida
De classe	Descritiva	Reações humanas	Interpretada
Universal			Analítica
Hipotética			Sintética

Quanto à faceta do escopo, a modelagem pode ser: individual, quando os modelos se referem a jogadores específicos, permitindo comparações entre jogadores (não se restringindo apenas a jogadores humanos); de classe, quando se referem a categorias de jogadores, particionando o espaço de jogadores em estereótipos; universal, quando o modelo se aplica a todos os jogadores (um exemplo citado pelos autores é o de uma função de mensuração de diversão aplicada aos jogadores sem distinções específicas); hipotética, quando o modelo é projetado baseado em um tipo de jogador em específico através de suposições sobre seu comportamento.

Quanto à faceta do propósito, a modelagem pode ser: geradora, quando o modelo gera dados que poderiam ser adquiridos a partir de um jogador (por exemplo, na criação ou reprodução de determinados comportamentos para simular jogadores); descritiva, quando seu intento é fornecer informações sobre o jogador para diversos usos (por exemplo, um mapa de locais frequentados no jogo).

Quanto à faceta do domínio, a modelagem pode ser em relação a: ações de jogo, quando se refere a ações do jogador dentro do jogo (e.g., personalização do avatar, escolhas de movimentação, *upgrades*, etc.); reações humanas, quando se refere a propriedades da experiência de jogo externas à realidade simulada do jogo (e.g., dados de movimentação ocular do jogador, nível de diversão ou frustração do jogador).

Quanto à faceta da fonte da derivação, a modelagem pode ser: induzida, quando o modelo usa dados gravados com uma análise objetiva induzida (e.g., a modelagem de jogador de Houlette (Houlette04)); interpretada, quando a modelagem é mais subjetiva que a induzida, podendo requerir uma intervenção humana para as observações empíricas em descrições informativas; analítica, quando o modelo é criado a partir da utilização métodos automatizados que extraem características do próprio *game design* (e.g., uso de métodos de otimização e de aprendizado); sintética, quando o modelo é derivado de um conceito externo ao próprio jogo (e.g., a definição de fluxo e de diversão citadas no capítulo 2).

## 4.2

### Usos de modelagem de jogador

A modelagem de jogador é tradicionalmente usada no contexto de detecção de preferências de jogador e ajuste dinâmico de dificuldade, como visto no capítulo 3. Machado et al. (Machado11a, Machado11c) identificam também o uso de modelagem de jogador como ferramenta no auxílio ao *game design*, como forma de diversificar e tornar NPCs similares a jogadores reais e em *storytelling* interativo, podendo ser utilizada para melhorar a experiência do interator com a narrativa.

Além dos usos dentro da adaptatividade em um jogo específico, Houlette (Houlette04, p. 565) propõe que o modelo de jogador possa ser exportado para outros jogos que usem uma modelagem compatível. Outro uso possível seria como forma de *feedback* ao jogador, apresentando seu modelo final e evolução em forma de gráficos, porém com a possibilidade de expor a inteligência artificial ao jogador e com isso permitir sua exploração.

## 4.3

### Técnicas

Houlette diz que: “...escolher o conjunto correto de características para seu modelo de jogador é, como muito do desenvolvimento de jogos, mais arte que ciência.” (Houlette04, p. 558), sendo que o modelo é dependente do jogo em si e frequentemente incompatível com outros jogos. Suas propostas de regras gerais para o desenvolvimento de modelos de jogador são: capturar os aspectos importantes da jogabilidade no modelo; modelar de forma a complementar as estratégias da inteligência artificial; ou montar uma modelagem que sirva de base para definir a especificação de requisitos da inteligência artificial. Houlette sugere também a utilização de modelos hierárquicos de jogador (Houlette04, p. 563–564), onde certas características podem ser compostas de outras características mais específicas, como visto na Figura 4.1.

Machado et al. (Machado11a) discutem diversas técnicas usadas para modelagem de jogador: funções de avaliação, redes neurais, modelos baseados em regras, máquinas de estado finito, modelos probabilísticos, modelos baseados em casos e algoritmos evolutivos. Demasi e Cruz (Demasi03c) usam lógica *fuzzy* para construir modelos de jogador para adaptatividade, criando regras a partir do aprendizado com o jogador.

O uso de funções de avaliação envolve uma busca em um espaço de possibilidades, organizado como um grafo (Machado11a), usando a função de avaliação para comparar o modelo atual do jogador.

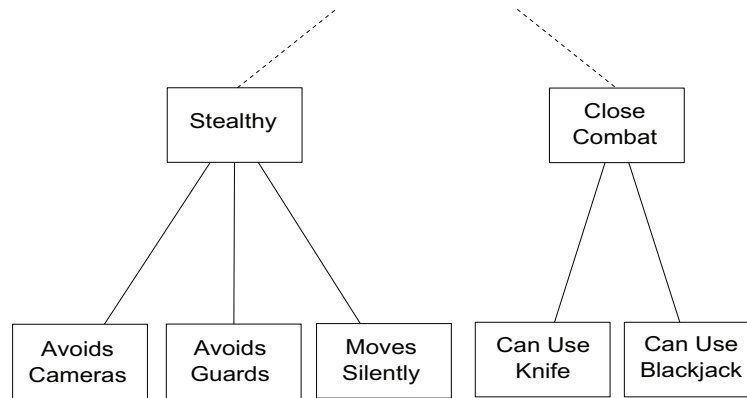


Figura 4.1: Exemplo de modelo de jogador hierárquico. Retirado de (Houlette04, p. 563).

Redes neurais podem ser usadas para coletar estatísticas de diversos jogadores humanos ou agentes inteligentes e a formar modelos de jogadores partir desses dados, usando algoritmos de *clustering*. Os trabalhos de Yannakakis et al. (Yannakakis05, Yannakakis08a, Yannakakis08b, Pedersen09) usaram redes neurais para gerar modelos de jogador e analisam seu impacto na experiência de jogo através da satisfação do jogador.

Modelos baseados em regras são séries de precondições que se satisfeitas resultam em ações. Uma variação desses modelos são máquinas de estado finito, máquinas *fuzzy* de estado finito, modelos probabilísticos e árvores comportamentais.