

INTERFACE: STRUMENTI INTERATTIVI PER L'ANIMAZIONE DELLE TESTE PARLANTI

Graziano Tisato, Piero Cosi, Carlo Drioli, Fabio Tesser
ISTC – SFD – CNR

Istituto di Scienze e Tecnologie della Cognizione
Sezione di Padova - Fonetica e Dialettologia
Via G. Anghinoni, 10 - 35121 Padova - Italia
{tisato, cosi, drioli, tesser}@pd.istc.cnr.it

SOMMARIO

Gli sviluppi recenti della ricerca nel campo delle teorie sulla produzione e percezione della lingua parlata, così come nel campo tecnologico dell'interazione uomo-macchina (riconoscimento della voce, sintesi di agenti conversazionali, insegnamento delle lingue, riabilitazione della voce, ecc.) richiedono l'acquisizione e l'elaborazione di grandi quantità di dati articolatori ed acustici. È noto, infatti, che questi dati si differenziano da lingua a lingua per la dimensione e la struttura dell'inventario fonologico. D'altra parte, la richiesta di questo tipo di dati è aumentata negli ultimi anni con il crescente interesse manifestato dalla comunità scientifica nel campo delle emozioni.

Questo articolo presenta **InterFace**, un ambiente interattivo realizzato all'ISTC-SPFD (<http://www.pd.istc.cnr.it/LUCIA/home/tools.htm>) con lo scopo di facilitare tutte le fasi di analisi, elaborazione, e sintesi dei dati necessari all'animazione audio-visuale delle **Teste Parlanti**.

InterFace permette di raggiungere tre principali finalità:

- Estrarre dai dati acquisiti un insieme di misure su parametri articolatori (ad es. apertura labiale, arrotondamento, protrusione, agrottamento, asimmetrie labiali, ecc.), espressamente definiti dall'utente, e riguardanti tanto l'ambito tradizionale della fonetica che quello più recente delle emozioni.
- Ottenere da quegli stessi dati una modellizzazione parametrica dell'evoluzione dei parametri fonetici, che tenga in debito conto i fenomeni di coarticolazione, e che possa essere impiegato nei motori di animazione delle Teste Parlanti.
- Creare da varie fonti il flusso dei dati audio-visuali necessari all'animazione di un agente conversazionale, capace di esprimere emozioni.

Il sistema può maneggiare quattro differenti tipi di dati in ingresso:

- **Dati reali**, acquisiti da sistemi di cattura degli andamenti cinematici dell'articolazione facciale. L'elaborazione di questi dati permette di realizzare una tipica **Data-Driven Synthesis**.
- **Dati testuali**, da cui generare il flusso di dati audio-video di controllo dell'animazione facciale. Seguendo questo via, si ottiene una **Text-to-Animation Synthesis**, ovvero una **Symbolic-Driven Synthesis**.
- **Dati audio**, da cui ricavare la segmentazione fonetica con un sistema di riconoscimento automatico e ottenere in questo modo la sequenza dei fonemi necessari ad una animazione sincrona con l'audio. Questo procedimento può essere chiamato una **Wav-to-Animation Synthesis**.
- **Dati a basso livello**, per controllare manualmente il movimento di uno o più parametri di animazione e verificarne l'effetto con la sintesi video. Quest'ultimo procedimento si può definire come una **Manual-Driven Synthesis**.

1. INTRODUZIONE

Un paradigma, che trova attualmente largo consenso nella comunità scientifica, sostiene che la natura della comunicazione parlata e della trasmissione delle emozioni è inerentemente multimodale. Secondo questo principio, le informazioni linguistiche e paralinguistiche, provenienti tanto dal canale uditivo che da quello visivo si integrano a vicenda, agevolando il processo comunicativo. Una prova viene dall'esperienza di tutti i giorni, per cui si verifica che l'intelligibilità del linguaggio aumenta notevolmente, anche in condizioni di ascolto pessime, quando si possa vedere la faccia dell'interlocutore che ci parla. Da un punto di vista linguistico, test di intelligibilità hanno portato all'individuazione di una serie di visemi, che sono l'equivalente visivo dei fonemi (si veda per l'italiano: Magno Caldognetto *et alii*, 1993, 1997, 1998, Così & Magno Caldognetto, 2002).

Queste considerazioni spiegano come la ricerca si sia focalizzata da qualche decennio nel campo della trasmissione e della percezione audio-visuale, o bimodale, del linguaggio, sia dal punto di vista teorico, per la formulazione di teorie che ne spieghino i meccanismi di funzionamento (McGurk & MacDonald, 1976; Summerfield, 1987; Massaro, 1987,1996, 1998; Stork & Henneke, 1996), sia per fornire il supporto ai vari settori tecnologici, che si occupano dell'interazione uomo-macchina (Stork & Henneke, 1996; Massaro *et alii*, 2000; Magno Caldognetto *et alii*, 2001; Prendinger & Ishizuka, 2004), come, ad esempio, il riconoscimento automatico (Walden, 1977; Petajan, 1984; Stork *et alii*, 1992; Silsbee, 1993; Adjoudani & Benoit, 1995), la sintesi (Parke, 1974, 1982; Cohen & Massaro, 1990; Benoit *et alii*, 1992, 1996; Le Goff *et alii*, 1994, 1996; Le Goff, 1997; Lee *et alii*,1995; Beskow, 1995; Vatikiotis-Bateson, 1996; Massaro *et alii*, 2000; Pelachaud, 2001, Così *et alii*, 2001, 2002c, 2003a), le telecomunicazioni (Stork & Henneke, 1996; Chen & Rao, 1998); l'insegnamento (Così & Magno Caldognetto, 2003b; Biscetti *et alii*, 2004) e la riabilitazione del linguaggio (Così *et alii*, 2004a).

A questo si è aggiunta negli ultimi anni una attenzione crescente per lo studio delle emozioni, che deriva dalla riconosciuta importanza del condizionamento, conscio e inconscio, che esse esercitano nelle relazioni interpersonali e nello sviluppo umano (Ekman & Friesen, 1977, 1978; Massaro & Egan, 1998; Cohen *et alii*, 1998; Cowie *et alii*, 2001; Douglas_Cowie & Campbell, 2003; Keltner, 2003).

Per quanto riguarda le applicazioni tecnologiche, è diffusa l'opinione che l'introduzione della bimodalità e delle emozioni possa migliorare in modo sostanziale l'efficacia e la naturalezza della comunicazione uomo-macchina. Mentre tradizionalmente i dati acustici e quelli visivi, tanto del parlato che delle emozioni, sono stati analizzati ed utilizzati separatamente (Cahn, 1990; Banse & Scherer, 1996; Scherer, 2003; Scherer *et alii*, 2003), le ricerche più recenti hanno introdotto la bimodalità e l'espressione delle emozioni negli agenti conversazionali (Pasquariello, 2000; Pelachaud, 2001; Bilvi, 2002; Magno Caldognetto *et alii*, 2003, 2004; Drioli *et alii*, 2003, 2004). Per quanto riguarda l'audio, gli studi del passato hanno portato ad una categoria di sintetizzatori vocali (sistemi ad unità variabili, o *Automatic Unit Selection*) in grado di generare una voce decisamente più naturale e fluente dei sistemi precedenti (vedi ad esempio www.loquendo.it), che erano basati su la concatenazione di un numero limitato di difoni, oppure sul modello sorgente-filtro. Come i precedenti, comunque, anche i sistemi ad unità variabili risentono di un *handicap* implicito nella loro architettura, e cioè la mancanza di capacità espressive. Sia che si tratti della lettura del telegiornale o del racconto di una favola, che si tratti di una notizia buona o di una cattiva, il sintetizzatore in questione continuerà a produrre lo stesso identico flusso sonoro nelle diverse circostanze. I tentativi di sintesi audio più recenti vanno in due

direzioni: la prima prevede l'acquisizione di *corpora* di dati per i sistemi ad unità variabili già predisposti per un certo numero di emozioni (Iida *et alii*, 2003). La seconda segue la strada di aggiungere al motore di sintesi gli opportuni controlli sia per i parametri prosodici (Tesser *et alii*, 2003, 2004) che per quelli spettrali (Rank & Pirker, 1998, Drioli *et alii*, 2003, 2004), che si adattino in maniera flessibile al significato del messaggio e allo stato emotivo che devono veicolare.

Le linee di tendenza suddette, bimodalità ed emozioni, hanno avuto due conseguenze immediate: da un lato, l'esigenza di acquisire grandi quantità di dati audio-visuali, dal momento che essi risultano essere specifici di ogni lingua e dialetto, e anche di ogni emozione (Cosi *et alii*, 2002b). Dall'altro, la necessità che ci sia sincronia fra dati acustici e visivi, dal momento che si vogliono comprendere il ruolo e l'influenza reciproca dei parametri nella produzione e percezione della comunicazione umana.




Figura 1 – Schermata principale del programma InterFace, che evidenzia tre aree funzionali: elaborazione, editing dei dati audio-visuali e animazione con Lucia e Greta.

Una esigenza ulteriore è legata alla quantità dei dati da processare, che nel caso di un sistema a difoni tradizionale è normalmente dell'ordine delle migliaia di stimoli per ogni lingua, dialetto, o emozione presa in considerazione. Nel nostro caso, il software, messo a disposizione con il sistema ELITE (ELaboratore di Immagini TELEvisive) (Ferrigno & Pedotti, 1985; www.bts.it), imponeva di configurare manualmente la maschera di riferimento dei punti facciali, di cui il programma doveva ricostruire il movimento, per ognuno delle migliaia di *file* acquisiti. A questo si doveva sommare una fase molto più lunga e faticosa di interventi manuali necessari per la correzione degli errori molto frequenti di tracciamento delle traiettorie, dovuti alla vicinanza dei punti e alla loro rapidità

di movimento. Il tempo richiesto dalla elaborazione degli stimoli si traduceva in parecchi mesi di lavoro certosino, che metteva a dura prova la pazienza e gli occhi del malcapitato operatore.

Sono questi alcuni motivi che hanno imposto lo sviluppo di mezzi tecnologici adeguati alla complessità del compito, e che hanno portato alla creazione di un software apposito, chiamato **InterFace** (<http://www.pd.istc.cnr.it/LUCIA/home/tools.htm>).

I vantaggi immediati di questo software si possono misurare nella riduzione dei tempi di elaborazione, che erano dell'ordine di molti mesi, calati ora a pochi giorni, e la drastica contrazione dei tempi di realizzazione e di test dell'animazione delle facce parlanti.




Figura 2 – Animazione delle Talking Heads in modalità server.

2. INTERFACE

InterFace è un ambiente di sviluppo interattivo e flessibile, realizzato all'ISTC-SPFD in Matlab, con lo scopo di accelerare l'analisi dei dati bimodali, e l'estrazione, la modellizzazione ed il test dei parametri necessari all'animazione audio-visuale.

In Fig. 1 si può vedere la schermata principale del programma, in cui si nota la barra con i menu in alto, e la divisione in tre blocchi funzionali principali, con l'elaborazione dei dati a sinistra, i dati intermedi di animazione al centro, e a destra la sintesi con gli agenti Greta e Lucia (www.pd.istc.cnr.it/lucia).

Nella barra dei menu, il pulsante *Options* permette di configurare le differenti applicazioni (compresa la lingua utilizzata) e di salvare i parametri in un *file* di inizializzazione.

Le funzionalità dell'area dei dati intermedi riguardano l'allocazione e l'eventuale *editing* dei due *file* contenenti rispettivamente l'audio e i dati di animazione, generati secondo lo standard MPEG-4 (mpeg.telecomitalia.com/standards/MPEG-4), e cioè i Facial Animation Parameters (FAPs) (Doenges, 1997; Lavagetto & Pockaj, 1999).

Per quanto riguarda l'area della sintesi, le facce parlanti possono essere attivate localmente di volta in volta, oppure lanciate in modalità *server* con l'apposito pulsante, trasmettendo e ricevendo i dati di animazione localmente oppure sulla rete *Web* ad uno specifico indirizzo IP (Fig. 2).

Si può con l'apposito controllo escludere l'audio dalla sintesi della faccia.

L'area dell'elaborazione è la parte fondamentale di **InterFace**. Contiene le applicazioni sviluppate per trattare i dati, suddivisi secondo la loro tipologia, e cioè: **Dati bimodali** (vedi cap. 3-5), **Dati XML e testuali** (cap. 6), **Dati audio** (cap. 7), e **Dati a basso livello** (cap. 8).

3. ELABORAZIONE DEI DATI BIMODALI

I **Dati reali bimodali** sono acquisiti da ELITE, un sistema optoelettronico che cattura gli andamenti cinematici di *marker* riflettenti la luce all'infrarosso, e che contemporaneamente campiona l'eventuale segnale audio presente.




Figura 3 – Fotogrammi 3D di dati reali ricostruiti con Track (in alto), e risintesi (Data-Driven Synthesis) di una faccia esprimente gioia.

I dati audio-visuali provenienti da ELITE possono essere manipolati da quattro diverse applicazioni:

- **Track**: permette la ricostruzione 3D delle traiettorie dei *marker* applicati sulla faccia di un soggetto (vedi Fig. 3-7). Questi dati sono poi passati alle altre applicazioni (Optimize, APmanager e Mavis) per le successive fasi di elaborazione. Track consente anche di risintetizzare l'animazione facciale, convertendo queste traiettorie in un flusso di controllo secondo un protocollo voluto (attualmente MPEG-4). Si ottiene in questo modo una tipica **Data-Driven Synthesis** (Fig. 3) (Damper, 2001; Cosi *et alii*, 2004b).
- **Optimize**: utilizza i dati provenienti da Track per estrarre i coefficienti di articolazione fonetica (cap. 5). I valori di questi coefficienti sono ottimizzati secondo un criterio di minimizzazione dell'errore da un modello di Cohen-Massaro (Cohen & Massaro, 1993), che è stato modificato per tener conto della coarticolazione (Perin, 2001; Cosi *et alii*, 2002a, 2002c; 2003a). Questo termine indica il fenomeno di variabilità acustica ed articolatoria delle unità fonetiche, che risultano fortemente dipendenti dal contesto in cui si trovano (Öhman, 1966, 1967; Henke, 1966; Daniloff & Moll, 1973; Bladon & Al-Bamerni, 1976; Bell-Berti & Harris 1981; Al-Bamerni & Blandon, 1982; Keating, 1990; Farnetani & Recasens, 1999). Il modello è stato implementato in **AVengine**, che è il motore per l'animazione da testo scritto (**Text-to-Animation Synthesis**) e da file audio (**Wav-to-Animation Synthesis**).
- **APmanager**: consente di stabilire un certo numero di misure fra i dati articolatori forniti da Track, rispetto a punti, rette o piani di riferimento opportunamente definiti (Fig. 4, cap. 4.5).
- **Mavis**: è usato per visualizzare e segmentare i parametri articolatori calcolati da APmanager (cap. 4.5) (Tiede *et alii*, 1999).

4. TRACK

Questo programma permette la ricostruzione tridimensionale delle traiettorie di appositi *marker*, e cioè dischetti di plastica applicati sulla faccia di un soggetto e riflettenti la luce infrarossa (Fig. 4-7). In Fig. 4 si vedono i punti da noi usati in due diverse configurazioni: la prima adottata in passato per misure dei soli movimenti labiali (8 punti grigi), e la seconda adottata più recentemente per ottenere un maggior dettaglio articolatorio e per studiare le emozioni (28 punti fra rossi e grigi). Si notano anche i piani di riferimento convenzionali (frontale, trasversale e sagittale) rispetto ai quali si possono definire ed estrarre le misure dei parametri voluti. In Fig. 5 è riportata la posizione assoluta nello spazio dei punti sulla faccia del soggetto che è ripreso, e i punti (rovesciati) così come risultano captati sul piano focale di due telecamere (Fig. 6). In Fig. 7, infine, si vedono le traiettorie 3D effettivamente ricostruite dei *marker*, nel caso della pronuncia di una frase ("Chiudo...Il fabbro lavora con forza usando il martello e la tenaglia"), simulando tristezza.




Figura 4 – Piani di riferimento e punti usati in due diverse configurazioni per l'acquisizione dei movimenti articolatori.

La cattura dei movimenti articolatori avviene, nel nostro caso, con una prima fase di acquisizione dei dati in tempo reale mediante il sistema ELITE. I dati sono acquisiti sotto forma di coordinate xy dei *marker*, sul piano focale di un certo numero di telecamere (vedi Fig. 6). L'uso di *marker* passivi ha il grande vantaggio di non ostacolare in nessun modo il movimento degli articolatori della faccia del soggetto, ma presenta anche uno svantaggio non indifferente rispetto all'uso di *marker* attivi: il sistema rileva la posizione dei punti, ma non può facilmente risalire alla loro identità, proprio perché questa dovrebbe essere dedotta dalla sola luminosità. Due punti troppo vicini, ad esempio, possono essere interpretati come uno solo, e la sua posizione di quest'ultimo non concorda con nessuno dei due punti originali, poiché il calcolo è basato sul centroide della luminosità dei pixel contigui nell'immagine catturata. I risultati dell'acquisizione possono inoltre essere errati per altri

motivi: per la mancanza di punti e/o per la presenza di punti spuri dovuti a riflessi luminosi. È dunque necessaria una seconda fase di post-elaborazione per tentare la corretta identificazione dei punti. Una volta individuati i punti e le loro coordinate 2D, con una tipica procedura di stereofotogrammetria è possibile risalire alla posizione effettiva nello spazio 3D, che non è altro che il punto in cui coincidono le proiezioni passanti attraverso i punti 2D del piano focale e l'obbiettivo della TV relativa (Fig. 5) (Wolf, 1983).




Figura 5 – **Track**: Ricostruzione della posizione 3D (in mm) dei punti della faccia a destra (magenta) dalle immagini 2D catturate dalle telecamere a sinistra (verde e blu). L'origine delle coordinate è nel parallelepipedo (volume di calibrazione) della faccia originale.

In Fig. 6 si può vedere un fotogramma con la posizione di 28 punti di una certa configurazione sul piano focale di due telecamere. Le TV devono essere almeno due per ottenere le due rette di proiezione indispensabili per determinare il punto di coincidenza suddetto. Le misure in mm si riferiscono alla distanza dei punti dall'asse focale delle TV.

Per arrivare a posteriori all'identità dei punti tracciati, nel caso della faccia, come di un oggetto meccanico, è necessario separare il movimento di una delle parti, da quello di roto-traslazione dell'intero sistema. In questo modo, si evita di confondere l'inclinazione in avanti o indietro di tutta la testa, ad esempio, con un moto verso il basso o verso l'alto degli articolatori facciali, che non si sta verificando o che avviene in senso contrario (vedi Fig. 3). In un corpo rigido, le distanze dei punti da tracciare rimangono costanti. È quindi facile calcolare le componenti di roto-traslazione e il conseguente cambio delle coordinate, che permette di misurare gli spostamenti relativi delle parti volute. In una faccia, ed in particolare nella bocca, queste distanze subiscono delle modifiche notevoli, per cui bisogna disporre almeno di un triangolo di punti indeformabili, su cui si possa basare la trasformazione degli assi cartesiani.




Figura 6 – **Track**: visualizzazione e animazione dei punti 2D non ancora identificati di un fotogramma di una faccia esprimeente rabbia. In questo caso, sul piano focale delle 2 TV compaiono tutti i 28 *marker* di acquisizione.

Solo le misure differenziali, calcolate cioè come differenza della posizione reciproca di due punti (ad es. apertura labiale, arrotondamento, ecc.), sono immuni da errori. Le altre risultano affette da un errore tanto più rilevante, quanto maggiore è la deformazione del triangolo. Anche un triangolo formato dalla punta del naso e dalle due orecchie, che è stato usato in passato, è soggetto a deformazioni. Questo è particolarmente evidente nel caso delle emozioni, che provocano spostamenti sensibili della punta del naso e dei lobi delle orecchie. È necessario, dunque, disporre di un triangolo di punti che non subisca alterazioni per effetti articolatori, come potrebbe essere, ad esempio, uno solidale con la calotta cranica.

Come era stato anticipato nell'introduzione, il software fornito con il sistema ELITE, progettato per il movimento di arti rigidi, si è dimostrato inadeguato nella ricostruzione 3D delle articolazioni e delle espressioni facciali, per la vicinanza e la deformazione della struttura dei *marker* di rilevamento. Un secondo, ma non meno grave, ostacolo è costituito dalla necessità di settare, per ognuno delle migliaia di stimoli acquisiti, una apposita maschera, o modello di riferimento, che stabilisce la corrispondenza fra i punti rilevati e la loro identità, e consente la loro corretta attribuzione alle traiettorie corrispondenti. La eccessiva propensione agli errori del programma fornito con ELITE e la richiesta di un continuo intervento operativo rendevano impossibile affrontare in tempi ragionevoli l'elaborazione di migliaia di *file*.

- Il *FAP-stream* prodotto tiene conto della roto-traslazione della testa e dei fattori di scala della testa che si vuole animare, il che permette una corretta **Data-Driven Synthesis** di un qualsiasi agente MPEG-compatibile.

In Fig. 8 si può vedere la pagina introduttiva del programma con le principali aree funzionali: **Operazioni su file singoli**, **Operazioni su directory**, **Elaborazione**, **Sintesi**.

L'area sulla sinistra riguarda le operazioni compiute su un singolo *file* di dati, e comprende la ricostruzione 3D di cui abbiamo parlato in precedenza, la conversione a dati MPEG-compatibili, la visualizzazione e l'*editing* delle traiettorie bi- e tri-dimensionali dei *marker*, e la costruzione del modello di riferimento, che, come detto, è unico per tutta la sessione di lavoro (cap. 4.2).

L'area in basso riporta la corrispondenza fra i parametri di animazione FAP e le traiettorie dei *marker* che si vogliono controllare, in vigore in quel momento. La presenza di più di un numero identificativo per i FAP significa che il controllo avviene lungo diversi assi cartesiani. Ad esempio, la prima casella a sinistra *Mn*, relativa al mento contiene il movimento su tutti e tre gli assi di riferimento. Un clic sui pulsanti relativi permette di riconfigurare a piacere la corrispondenza *marker*-FAP (cap. 4.4).




Figura 8 – Schermata principale del programma **Track**.

4.2. TRACK: CONFIGURAZIONE DEL MODELLO DI RIFERIMENTO

Il modello di riferimento permette di identificare i punti rilevati dal sistema ELITE. È necessario impostarlo solo una tantum e, come detto, rimane unico per tutta una sessione di lavoro, ovverosia per tutti i *file* di acquisizione, in cui la collocazione dei *marker* sulla faccia del soggetto non sia stata alterata. La configurazione è fatta attribuendo una etichetta ad ognuno dei punti, ed eventualmente collegandoli con linee colorate che possano rendere l'animazione più fruibile (Fig. 9), ed è poi salvata in un *file* opportuno. La posizione dei punti della maschera può essere letta direttamente da uno qualsiasi dei *file* di acquisizione corrispondenti a quella sessione, o anche, volendo, impostata manualmente nel *file* di configurazione.

L'identificazione avviene confrontando i punti del modello di riferimento con quelli del fotogramma corrente nel *file* in analisi, dopo che la SVD ha permesso la roto-traslazione dei

dati in modo da farli combaciare con il riferimento. A questo punto l'identità di un punto incognito deriva dalla minima distanza con uno dei punti noti (*nearest neighbour association rule*). Una volta soddisfatti certi criteri (che non ci siano errori di doppie assegnazione e che compaiano tutti i *marker*), il fotogramma dei dati correnti diventa la nuova maschera, o nuovo modello di riferimento, adattandosi progressivamente anche a grandi deformazioni temporali della struttura dei punti.




Figura 9 – **Track**: Modello di riferimento per la ricostruzione delle traiettorie articolatorie facciali.

4.3. TRACK: RICOSTRUZIONE DELLE TRAIETTORIE DEI MARKER

In Fig. 8 si possono vedere a sinistra i parametri che possono controllare la ricostruzione delle traiettorie articolatorie, e che permettono la visualizzazione 2D e 3D fotogramma per fotogramma, l'*editing*, il filtraggio e l'interpolazione dei dati.

Uno di questi parametri è la massima variazione tollerabile in mm dello spostamento di un punto da un fotogramma all'altro. Questo permette di decidere se la nuova posizione può essere considerata accettabile, o fuori scala. Il parametro va aggiustato a seconda degli stimoli registrati, aumentando l'escursione possibile, se si tratta di emozioni, ad esempio, in cui i movimenti risultano molto ampi.

Altri parametri permettono di scegliere se interpolare o no i dati, e quale tipo di interpolazione (cubica, *spline*, lineare) si voglia applicare. In caso di una traiettoria con pochi punti mancanti il risultato migliore è dato dalla *spline* (vedi Fig. 10).

Si può decidere anche se applicare un filtraggio passabasso o no, tenuto conto che nella fase di estrazione dei veri e propri parametri articolatori il filtraggio sarà comunque forzatamente imposto (cap. 4.5). In Fig. 11 si vede il risultato del filtraggio con un filtro Lambda (*Linear-Phase Autoregressive Model-Based Derivative Assessment Algorithm*) appositamente studiato per questo tipo di applicazioni (D'Amico & Ferrigno, 1990, 1992).




Figura 10 – **Track**: Tipi di interpolazione nella ricostruzione di traiettorie articolatorie.

4.4. TRACK: CONFIGURAZIONE DELLA CORRISPONDENZA MARKER-FAP

Per l'animazione si è adottato il protocollo MPEG-4, che offre vari vantaggi fra cui il fatto che sia uno standard di accesso in rete alle *Talking Heads* (Fig. 2). MPEG-4 ha la possibilità di:

- Animazione a distanza con un flusso di dati, chiamati *Facial Animation Parameters* (FAPs), di una faccia 3D costruita su un reticolo (*mesh*) poligonale di punti. Le nostre facce parlanti, Lucia e Greta, utilizzano per l'animazione un approccio pseudo-muscolare, nel quale la contrazione del muscolo è ottenuta attraverso la deformazione della *mesh* attorno a punti particolari (*feature points*), che corrispondono all'attaccatura dei muscoli facciali. Ai FAPs, prima definiti, corrispondono minime azioni facciali.
- Adattamento dei FAPs alla conformazione di una particolare faccia mediante i *Facial Animation Parameter Units* (FAPU).
- Definizione eventuale dell'intera struttura della faccia con i *Facial Definition Parameters* (FDPs), con cui impone fra l'altro la tipologia maschio o femmina, vecchio o giovane, e altri particolari come occhiali, cappello, ecc.

Per gli scopi di ricerca fonetica e nel campo delle emozioni, è molto importante disporre di mezzi che permettano la rapida configurazione e manipolazione di questi parametri. È per questo motivo che si è creato un apposito *tool* per stabilire la corrispondenza fra i punti di acquisizione con ELITE e quelli dello standard MPEG-4 (Fig. 12).

4.5. ESTRAZIONE DEI PARAMETRI ARTICOLATORI: APMANAGER E MAVIS

Le grandezze articolatorie significative dal punto di vista fonetico e delle emozioni sono ricavate dai dati fisici delle traiettorie nello spazio 3D, depurati dalle componenti di rototraslazione della testa (vedi inizio del cap. 4).

Per far questo, si è creato un programma **APmanager** (*Articulatory Parameter Manager*) che permette di determinare una qualsiasi misura voluta del tipo: distanza da *marker* a *marker*, distanza da *marker* ad una retta prestabilita, distanza da *marker* da un piano di riferimento (Fig. 4), angolo fra rette e/o piani voluti.

In Fig. 13 si può vedere la finestra principale del programma con un *file* di dati precedentemente elaborato da Track, il database contenente l'insieme dei parametri definiti fino a quel momento, e nel riquadro arancio il *set* dei parametri associati a questo *file*. Sovrapposto a questa, compare la finestra di configurazione di uno dei *set* di misure (in questo caso il *set* di nome Giulio), con i parametri che si vogliono ricavare in questo particolare caso: e cioè il movimento del labbro inferiore e superiore, l'apertura labiale, l'arrotondamento, la protrusione inferiore e superiore. Si può notare la definizione di una delle misure LabbroInf (spostamento verticale del labbro inferiore), come la distanza del *marker* Li (labbro inferiore) dal piano contenente naso e lobi delle orecchie. Nel caso delle emozioni si sono aggiunte altre misure riguardanti lo spostamento degli angoli della bocca e le asimmetrie destra e sinistra delle labbra, come si può vedere in Fig. 14, che mostra l'andamento di alcuni dei parametri visualizzati con **Mavis** (*Multiple Articulator Visualizer*, Tiede, 1999).




Figura 13 – **APmanager**: finestra principale e, sovrapposta, pannello di configurazione di un *set* di parametri con le misure ricavate da 8 *marker*.




Figura 14 – Parametri articolatori nella pronuncia della sequenza /aba/.

5. OTTIMIZZAZIONE DEI PARAMETRI ARTICOLATORI

È stato sviluppato un apposito modello di coarticolazione fonetica e un programma, **Optimize**, che estragga i coefficienti relativi dai dati reali provenienti da **Track**.




Figura 15 – **Optimize**: schermata principale con i parametri di ottimizzazione dell'articolazione del labbro inferiore per 5 prove di una transizione /aba/.

Come è stato accennato in precedenza, la coarticolazione è dovuta alla reciproca influenza dei movimenti articolatori durante la produzione del parlato, ed è responsabile della grande variabilità fonetica, che si verifica nelle lingue e dialetti. Questo fenomeno, di per sé stesso complesso e difficile da studiare, è complicato dall'influenza esercitata delle emozioni sull'articolazione fonetica.

Fra i molti modelli proposti in letteratura (Kozhevnikov & Chistovich, 1965; Öhman, 1966, 1967; Chomsky & Halle, 1968; Henke, 1966; Daniloff & Moll, 1973; Bladon & Al-Bamerni, 1976; Bell-Berti & Harris, 1981; Al-Bamerni & Blandon, 1982; Salzman & Munhall, 1989; Keating, 1990; Farnetani & Recasens, 1999), uno dei più convincenti sembra essere il modello di coarticolazione proposto da Cohen e Massaro (Cohen & Massaro, 1993) e basato sulla *gestural theory of speech production* di Löfqvist (Löfqvist, 1990; Munhall & Löfqvist, 1992). Secondo la teoria di Löfqvist, ad ogni singolo gesto articolatorio è associata una funzione di **dominanza** con le stesse caratteristiche dei gesti fonetici. Un funzione di **dominanza** ha la funzione di prevedere l'estensione anticipatoria (all'indietro) e l'estensione perseverativa (in avanti) di un segmento rispetto all'altro, ed è caratterizzata da una propria ampiezza, durata, e grado di attivazione. L'ampiezza determina l'importanza relativa del gesto per il segmento relativo; la durata stabilisce l'estensione del movimento ed influisce sul grado di sovrapposizione che ne conseguirà; il grado di attivazione caratterizza il fatto che il gesto si avvia in modo più o meno graduale. La **dominanza D** è una funzione esponenziale asimmetrica del tipo:

$$D(\tau) = \begin{cases} \alpha e^{-\theta_{bw} |\tau|^c} & \text{if } \tau \leq 0 \\ \alpha e^{-\theta_{fw} |\tau|^c} & \text{if } \tau > 0 \end{cases} \quad (1)$$

in cui τ rappresenta la distanza temporale dal centro del segmento fonetico, α rappresenta l'ampiezza della *dominanza*, θ l'estensione all'indietro (bw) o in avanti (fw) dell'influenza del segmento, e l'esponente c determina il grado di attivazione o pendenza della curva relativa, e può anche essere interpretato come grado di rilascio del movimento articolatorio.

Il metodo implementato da Cohen e Massaro è stato migliorato per realizzare transizioni più accurate fra *target* articolatori successivi e per risolvere parecchie difficoltà incontrate nella modellizzazione articolatoria delle consonanti bilabiali e labiodentali. Questo obiettivo è stato raggiunto in due modi:

- Adottando una nuova versione più generale delle funzioni di *dominanza*, che utilizza effettivamente l'esponente c per adattarsi alla diversa velocità del parlato.
- Aggiungendo al modello originale due nuove componenti dette **resistenza temporale e forma**.

La funzione **forma** ha l'effetto di modellare l'andamento del target articolatorio in prossimità del suo massimo rilievo, per cui otterremo un target non più discreto, ma variante nel tempo con una propria caratteristica. La funzione **forma** risulta utile nel riprodurre andamenti con caratteristiche particolari come ad esempio la pendenza rilevata nella produzione della vocale /u/ in alcuni contesti consonantici. Tuttavia, il ruolo fondamentale viene svolto in situazioni in cui si necessita di un rapido smorzamento come, ad esempio, nel caso del rilascio del gesto alla fine di una frase.

L'equazione per questa funzione è:

$$S_{LA}(\tau) = \begin{cases} \beta_{bw} \left| \frac{\tau}{h_{bw}} \right|^{p_{bw}} & +1 \text{ se } \tau < 0 \\ \beta_{fw} \left| \frac{\tau}{h_{fw}} \right|^{p_{fw}} & +1 \text{ se } \tau > 0 \end{cases} \quad (2)$$

dove *LA* indica una *forma* di tipo *Look-Ahead*, in cui l'influenza della funzione è proporzionale alla distanza con il target successivo o antecedente; dove h_{bw} e h_{fw} rappresentano fattori proporzionali alla distanza dai target precedenti o successivi;

La funzione di **resistenza temporale** è stata introdotta per avere la possibilità di bloccare i gesti articolatori, relativi sia al fonema precedente che a quello successivo, in modo da annullarne la reciproca influenza e di conseguenza imporre il raggiungimento forzato del target. Per far questo, ad ogni *dominanza* è stato associato un esponenziale negativo, denominato funzione di *resistenza temporale*, con un andamento simile alla *dominanza*, ma con estensione variabile in base alla collocazione dei fonemi precedenti o successivi ed al loro grado di resistenza.

$$R(\tau) = \begin{cases} e^{-6 \left| \frac{\tau}{h_{bw}} \right|^4} & \text{se } \tau < 0 \\ e^{-6 \left| \frac{\tau}{h_{fw}} \right|^4} & \text{se } \tau > 0 \end{cases} \quad (3)$$

dove h_{bw} e h_{fw} rappresentano come nella funzione *forma* fattori proporzionali alla distanza dai target precedenti o successivi

La formula completa della nuova funzione è la seguente:

$$F_{new}(t) = \frac{\sum_{i=1}^N T_i \cdot S_i(t-t_i) \cdot R_i(t-t_i) \cdot D_i(t-t_i)}{\sum_{i=1}^N R_i(t-t_i) \cdot D_i(t-t_i)} \quad (4)$$

dove N è il numero dei fonemi interessati, D è la *dominanza* relativa all' i -esimo segmento calcolata secondo l'equazione (1), S è la funzione *forma* data dalla formula (2) e R la *resistenza temporale* derivata dall'equazione (3).

La procedura di stima dei parametri è basata su metodo classico di minimizzazione dei minimi quadrati:

$$e = \sum_{r=1}^R \left(\sum_{n=1}^N (Y_r(n) - F_r(n))^2 \right) \quad (5)$$

fra i dati reali $Y(n)$ e le curve ottenute in uscita dal modello modificato $F(n)$, rappresentato dall'equazione (4), su un certo numero di ripetizioni R dello stesso tipo di sequenze (Fig. 16).

Il calcolo dei coefficienti viene eseguito in passi successivi che combinano analisi manuali e tecniche automatiche di ottimizzazione. Non è, infatti, possibile trattare i dati in modo completamente automatico, in quanto, per il modello utilizzato, la funzione costo presenta molti minimi globali e deve essere necessariamente guidata in modo manuale verso gli opportuni valori di target finali. Particolare attenzione è stata rivolta alla selezione del metodo di ottimizzazione. Essendo il numero di parametri in gioco molto alto (Fig. 15), si è presentata la necessità di sviluppare un algoritmo che avesse la proprietà di convergere velocemente verso il minimo in poche iterazioni. È stato scelto un metodo di tipo Trust Region con approssimazione del passo di aggiornamento in un sottospazio a due dimensioni che contenga il cammino calcolato secondo il metodo Dogleg (Schultz *et alii*, 1985). Tale metodo ha infatti una forte convergenza e garantisce, nel nostro caso, una buona approssimazione del minimo già in 10-15 iterazioni.

In Fig. 15 si possono vedere i coefficienti relativi alle varie funzioni *dominanza*, *forma* e *resistenza temporale* per la transizione /aba/. La presenza, o l'assenza, del segno di spunta vicino al valore indica che quel parametro è in quel momento soggetto al processo di ottimizzazione, oppure tenuto costante. In basso compaiono i valori di ampiezza e la posizione temporale dei *target* fonetici reali misurati dai dati di acquisizione.

In Fig. 16 si può vedere la curva temporale del labbro inferiore nella pronuncia di /aba/ e la curva approssimata secondo l'equazione (4) e i valori impostati come in Fig. 15. Compaiono anche le linee tratteggiate dei contributi separati delle relative funzioni di *dominanza*, *forma* e *resistenza temporale*.




Figura 16 – Optimize: Curva reale (in blu) e approssimata (in rosso) della transizione /aba/.

Meaning Semantic	DTD tag names	Abstraction level	Examples	APML
Emotions Expressions	affective	3	<fear>	
Voice Quality	voqual	2	<breathy> ... <tremulous>	VSML
Acoustic Controls	signalctrl	1	<asp_noise> ... <spectral_tilt>	

Figure 17: Struttura del linguaggio APML/VSML per la sintesi audio delle emozioni.

6. ANIMAZIONE DA XML E DA TESTO SCRITTO

Le Teste Parlanti hanno una applicazione ovvia nella lettura da testo scritto (*Text-to-Animation Synthesis*). Il programma che prepara il flusso di comando audio-visuale per un agente di animazione, è stato chiamato **AVengine**. Può ricevere in ingresso tanto un puro testo scritto, quanto un testo contenente parole chiave, come ad esempio un testo XML.

Nel caso del testo semplice, la sintesi audio e l'animazione video sono determinate unicamente dalla sequenza dei fonemi del testo in ingresso. Nel caso dell'audio, il risultato dipende anche dal tipo di *database* fonetico, che si stia utilizzando, e dalle regole

prosodiche che eventualmente si siano implementate (Tesser *et alii*, 2003,2004). In questo caso, come si diceva nell'introduzione, il risultato sonoro non può cambiare in relazione al contenuto del messaggio sintetizzato.

Per aggiungere espressività e emozioni alle *Talking Heads*, è necessario ricorrere a opportuni attributi, o *tag*, che siano poi interpretati dal motore di animazione, o meglio ad opportuni linguaggi che ne definiscano la grammatica, come può essere appunto l'**XML**.

Come è noto, il linguaggio **XML** (*Extensible Markup Language*) è stato creato nel 1996 dal W3C, e cioè il *World Wide Web Consortium*, come una specie di dialetto del più generale **SGML** (*Standard Generalized Markup Language*) che è lo standard internazionale di comunicazione sulla rete World Wide Web. La principale caratteristica di SGML e XML è che non sono semplicemente dei linguaggi di markup come l'**HTML** (*HyperText Markup Language*), ma meta-linguaggi che danno la possibilità all'utilizzatore stesso di definire la struttura del linguaggio, e cioè le parole chiave (o sintassi) e le regole (o grammatica), che descrivono le relazioni fra la struttura e il contenuto del documento. Questo insieme di definizioni è detto **Document Type Definition (DTD)**.

Altre caratteristiche che rendono **XML**, un linguaggio potente e flessibile, sono:

- L'estensibilità, che non pone limiti alla complessità lessicale e sintattica del linguaggio (a differenza dell'HTML, che ha un numero fisso di attributi).
- La possibilità di verificare la correttezza del testo XML in base alle definizioni date nel DTD.
- L'interoperabilità, che permette di condividere e riutilizzare i documenti sulla rete fra applicazioni e piattaforme hardware diverse.
- Il fatto che XML è un software *Open Source*.

Per permettere l'animazione espressiva delle *Talking Heads*, è stato creato un apposito DTD, chiamato **APML**, *Affective Presentation Markup Language* (De Carolis *et alii*, 2004). Il documento è un tentativo di definizione del comportamento degli agenti conversazionali, con l'introduzione di *tag* tipici degli atteggiamenti assunti nel corso di un dialogo, come ad esempio: *implore, order, suggest, propose, warn, approve, praise, recognize, disagree*, ecc., che fanno parte dell'elemento *performative*.

Si possono isolare quattro gruppi di funzioni comunicative:

- Le convinzioni dell'agente virtuale (attributo *certainty*, ecc.).
- Le sue intenzioni (attributi *performative, comment, belief-relation, turn-allocation*, ecc.).
- Il suo stato affettivo (attributo *affective*)
- Lo stato metacognitivo mentale (*i'm thinking, i'm planing*, ecc.)

È stata sviluppata una versione estesa del linguaggio APML, per aggiungere alla sintesi espressiva delle Facce Parlanti anche una sintesi audio, che simuli i correlati acustici caratteristici delle differenti emozioni (Drioli *et alii*, 2003, 2004). In questo modo i *tag* del linguaggio APML sono utilizzati per controllare tanto la parte visiva che la parte audio necessarie all'animazione.

Il nuovo modulo APML/VSML (dove VSML sta per *Voice Signal Markup Language*) ha una architettura gerarchica a tre livelli (Fig. 17). A livello più elevato di astrazione troviamo i *tag* relativi alle emozioni: *<anger>*, *<joy>*, *<fear>*, *<sadness>*, *<surprise>*, ecc. Questi ultimi sono a loro volta descritti a livello intermedio con la terminologia tipica della **Voice Quality**, in termini cioè di modalità di fonazione: *<modal>*, *<soft>*, *<pressed>*, *<breathy>*, *<whispery>*, *<creaky>*, ecc. Questi *tag* sono, infine, definiti al livello più basso della struttura in termini di caratteristiche acustiche basilari come: *<spectral tilt>*, *<shimmer>*, *<jitter>*, ecc.

La mappatura degli attributi APMML avviene dall'alto al basso, come nell'esempio di Fig. 17, in cui la paura <fear>, è interpretata con una tipologia di fonazione soffiata e tremolante (<breathy>, <tremolous>), ed espressa infine in termini di parametri fisici, come rumore di aspirazione, bilancio spettrale alte-basse frequenze, e modulazione della F0 (<asp. noise>, <spectral tilt>, <F0 modulation>, ecc.).

L'implementazione del nuovo APMML/VSML ha richiesto una modifica tanto del *parser* sintattico di FESTIVAL (Black *et alii*, [FESTIVAL Home Page](#)), che del sintetizzatore audio **Mbrola** ([Mbrola Home Page](#)), per poter operare le trasformazioni opportune nel tempo ed in frequenza del *pitch*, dell'ampiezza e del contenuto spettrale dei segmenti in questione. Una caratteristica interessante dell'implementazione è che l'applicazione delle trasformazioni non è statica, ma dinamica mediante l'uso di generatori di involuppo opportunamente comandati.




Figura 18 – Finestra principale del programma **FacePlayer**.

7. ANIMAZIONE DA FILE AUDIO

Un problema, che si incontra quando si voglia applicare una voce reale ad un agente virtuale, è ovviamente quello di sincronizzare il flusso visuale con quello sonoro. Dentro **InterFace**, si è voluto creare uno strumento che permetta di segmentare automaticamente un file audio esistente, e di ricavare la sequenza fonetica con le relative durate, necessaria per pilotare l'animazione sincrona con il parlato di partenza.

L'allineamento audio-visuale è ottenuto con un riconoscitore della voce basato su una rete neurale con architettura ibrida HMM/ANN, allenata sull'*Acoustic-Phonetic and Spontaneous Speech Corpus* (APASCI) dell'IRST (*Istituto per la Ricerca Scientifica e Tecnologica - Trento* www.itc.it/irst).

Come si era anticipato nell'introduzione, si realizza per questa via una tipica *Wav-to-Animation Synthesis*.



Figura 19 – Sequenza di controllo dell'apertura verticale delle labbra corrispondente alle funzioni definite in Fig. 18.

8. FACEPLAYER E EMOTIONPLAYER

Per lo sviluppo efficace delle applicazioni delle *Talking Heads*, è importante disporre di mezzi che permettano il test rapido dei parametri relativi all'animazione audio-visuale.

In Fig. 18 si può vedere la finestra principale di **FacePlayer**, che è nata per soddisfare le esigenze dette. **FacePlayer** permette di controllare il movimento di un unico FAP (o di un insieme voluto di FAPs), mediante funzioni schematizzate per punti ed poi interpolate. La scelta del punto da animare è fatta sulla faccia di sinistra, che mostra la situazione attuale della configurazione dei FAP, mentre nel riquadro a destra della figura si tracciano i punti corrispondenti. Anche in questo caso, come nella scelta della configurazione *marker-FAP* (cap. 4.4), si possono alterare i valori di scala, ovverosia i *Facial Animation Parameter Units* (FAPU), per adattare il *FAP-stream* alle dimensioni di una particolare faccia.

In Fig. 19 è riportato una sequenza di animazione con il movimento del labbro inferiore e superiore dedotto dalle funzioni disegnate in Fig. 18.

L'unica differenza di **EmotionPlayer**, rispetto a **FacePlayer** è la presenza di un **EmotionDisc** (Fig. 20), ispirato al lavoro di Zofia Ruttkay (Ruttkay *et alii*, 2003).




Figura 20 – Finestra principale del programma **EmotionPlayer**. Premendo sulle differenti zone del disco a sinistra si attivano un set di funzioni di controllo FAPs a destra.

Il disco è diviso in settori radiali corrispondenti alle sei principali emozioni (gioia, rabbia, paura, sorpresa, tristezza, disgusto), e in tre zone concentriche, corrispondenti a tre diversi livelli di intensità dell'emozione relativa. Premendo su una delle diverse zone si ottiene un set di funzioni di controllo dei FAPs, preterate e modificabili, le cui ampiezze

dipendono dal livello di intensità emotiva scelto, rispettivamente basso, medio, ed elevato. Nella Fig. 21 in basso, compare una sequenza di espressioni emotive reali dovute all'attore Fabio Fusco, e in alto una sequenza virtuale corrispondente, ottenuta con l'aiuto di **EmotionPlayer**. In Fig. 22, si possono vedere due espressioni corrispondenti a paura e gioia, e le relative funzioni di controllo.




Figura 21 – Simulazione con EmotionPlayer delle principali emozioni (in alto). In basso una sequenza reale interpretata dall'attore Fabio Fusco.




Figura 22 - Si possono vedere due espressioni corrispondenti a paura (in alto) e gioia (in basso), e le relative funzioni di controllo.

RINGRAZIAMENTI

Il lavoro è stato in parte finanziato dal progetto PF-STAR (*Preparing Future multiSensorial inTerAction Research*, European Project IST-2001-37599 <http://pfstar.itc.it>), e TICCA (*Tecnologie cognitive per l'Interazione e la Cooperazione Con Agenti artificiali*, in cooperazione fra il CNR e la Provincia Autonoma Trentina), e realizzato con la contributo di varie persone fra cui: Vincenzo Ferrari, Andrea Fusaro, Daniele Grigoletto, Enrico Marchetto, Giulio Perin, e Fabio Rossi della ditta B|T|S.

BIBLIOGRAFIA

- Adjoudani, C. Benoit. (1995), Audio-Visual Speech Recognition Compared Across Two Architectures, Proc. Eurospeech-95, Madrid (Spain), Vol. 2., 1563-1566.
- Al-Bamerni A., Blandon A. (1982), One-stage and two-stage patterns of velar coarticulation, *Journal of the Acoustical Society of America*, Vol. 72, Suppl. 1, 104.
- B|T|S Home Page: <http://www.bts.it>
- Banse, R., Scherer, K. R. (1996) Acoustic profiles in vocal emotion expression, *Journal of Personality and Social Psychology*, 70, 614-636.
- Bell-Berti F., Harris K.S. (1981), A Temporal Model of Speech Production, *Phonetica*, 1981, Vol. 38, 9-20.
- Benoit C., Lallouache T., Mohamadi T., Abry C. (1992), A Set of French Visemes for Visual Speech Synthesis, in Bailly G., Benoit C., Sawallis T.R. (Eds.), *Talking machines: Theories, Models, and Designs*, North-Holland, Amsterdam, 485-504.
- Benoit C., Guiard-Marigny T., Le Goff B., Adjoudani A. (1996), Which Components of the Face Do Humans and Machines Best Speech-Read?, in Stork D. and Hennecke M. (Eds.) *Speech-reading by humans and machine: models, systems and applications*, Springer-Verlag, New York, 315-328.
- Beskow J. (1995), Rule-Based Visual Speech Synthesis, in *Proceedings of Eurospeech '95, 4th European Conference on Speech Communication and Technology*, Madrid, 299-302.
- Bilvi M.(2002), *Progetto e Sviluppo di un Agente Conversazionale Multimodale: Animazione e Sincronizzazione dei Segnali Verbali e non Verbali*, M.S. Thesis, La Sapienza University, Rome.
- Biscetti S., Cosi P., Delmonte R., Cole R. (2004), Italian Literacy Tutor: un adattamento all'italiano del 'Colorado Literacy Tutor'", in *Atti DIDAMATICA 2004*, Ferrara (Italy), 249-253.
- Black A., Taylor P., Caley R., Clark R., The Festival Speech Synthesizer, <http://www.cstr.ed.ac.uk/projects/festival>
- Bladon R., Al-Bamerni A.(1976), Coarticulation Resistance in English, *Journal of Phonetics*, 4, 135-150.
- Cahn J. (1990), The Generation of Affect in Synthesized Speech, *Journal of the American Voice I/O Society*, Vol. 8, 1-19.

- Chen T., Rao R. (1998), Audio-Visual Integration in Multimodal Communications, *Proc. of the IEEE*, Vol. 86, no. 5, 837-852.
- Chomsky N., Halle M. (1968), *The Sound Pattern of English*, Harper and Row, New York, NY, 1968.
- Cohen M., Massaro D. (1990), Synthesis of Visible Speech, *Behaviour Research Methods, Instruments and Computers*, Vol. 22 (2), 260-263.
- Cohen M., Massaro D. (1993), Modeling Coarticulation in Synthetic Visual Speech, in Magnenat-Thalman N., Thalman D. (Eds), *Models and Techniques in Computer Animation*, Springer Verlag, Tokyo, 139-156.
- Cohen M., Walker R., Massaro D. (1996), Perception of Synthetic Visual Speech, in Stork D. and Hennecke M. (Eds.), *Speech-reading by Humans and Machine: Models, Systems and Applications*, Springer-Verlag, New York, 153-168.
- Cohen, M. , Beskow, J., Massaro, D. (1998), Recent Developments in Facial Animation: an Inside View, in *Proceedings of the International Conference on Auditory-Visual Speech Processing - AVSP'98*, Terrigal, Australia, 201-206.
- Cosi P., Magno Caldognetto E. (1996), Lip and Jaw Movements for Vowels and Consonants: Spatio-Temporal Characteristics and Bimodal Recognition Applications, in Stork D. and Hennecke M. (Eds.) *Speech-reading by Humans And Machine: Models, Systems and Applications*, Springer-Verlag, New York, 291-313.
- Cosi P., Tesser F., Gretter R., Avesani, C. (2001), Festival Speaks Italian!, *Proc. Eurospeech 2001*, Aalborg, Denmark, 509-512.
- Cosi P., Magno Caldognetto E., Perin G., Zmarich C. (2002a), Labial Coarticulation Modeling for Realistic Facial Animation, *Proc. ICMI 2002, 4th IEEE International Conference on Multimodal Interfaces 2002*, Pittsburgh (USA), 505-510.
- Cosi P., Magno Caldognetto E., Tisato G., Zmarich C. (2002b), Biometric Data Collection for Bimodal Applications, *Proc. of COST 275 Workshop, The advent of Biometric on the Internet*, Rome, 127-130.
- Cosi P., Ferrari V., Magno Caldognetto E., Perin G., Tisato G., Zmarich C. (2002c), GRETA e LUCIA: Due Realistiche Facce Parlanti Animate Mediante un Nuovo Modello di Coarticolazione, in *Atti delle XIII Giornate di Studio GFS 2002*, Pisa, 27-134.
- Cosi P., Fusaro A., Tisato G. (2003a), LUCIA a New Italian Talking-Head Based on a Modified Cohen-Massaro's Labial Coarticulation Model, *Proc. Eurospeech 2003*, Vol. III, 2269-2272.
- Cosi P., Magno Caldognetto E. (2003b), *E-learning e facce parlanti: nuove applicazioni e prospettive*, in *Proc. of XIV Giornate di Studio del G.F.S.*, Viterbo, Italy, (in press).
- Cosi P., Delmonte R., Biscetti S., Cole R. A., Pellom B., van Vuren S. (2004a), Italian Literacy Tutor, tools and technologies for individuals with cognitive disabilities", *Proc. of InSTIL/ICALL Symposium 2004*, Venice (Italy), 207-215.
- Cosi P., Fusaro A., Grigoletto D., Tisato G. (2004b), Data-Driven Tools for Designing Talking Heads Exploiting Emotional Attitudes, in *Proc. of Tutorial and Research Workshop, Affective Dialogue Systems*, Kloster Irsee (Germany), 101-112.

Cowie R., Douglas-Cowie E., Tsapatsoulis N., Votsis G., Kollias S., Fellenz W., Taylor J. (2001), Emotion Recognition in Human-Computer Interaction, *IEEE Signal Processing Magazine*, Vol. 8, no. 1, 32-80.

D'Amico M., Ferrigno G. (1990), Technique for the Evaluation of Derivatives from Noisy Biomechanical Displacement Data Using a Model-Based Bandwidth-Selection Procedure, *Medical & Biological Engineering & Computing*, 28, 407-415.

D'Amico M., Ferrigno G. (1992), Comparison Between the More Recent Techniques for Smoothing and Derivative Assessment in Biomechanics, *Medical & Biological Engineering & Computing*, 30, 193-204.

Damper R. (2001), Learning About Speech from Data: Beyond NETtalk, in *Data-Driven Techniques in Speech Synthesis*, R.I.Damper Ed., Kluwer Academic Publisher, 1-25.

Daniloff R., Moll K. (1973), On defining coarticulation, *Journal of Speech and Hearing Research*, 1973, Vol. 1, 239-248.

De Carolis B., Pelachaud C., Poggi I., Steedman M. (2004), APML, a Markup Language for Believable Behavior Generation, in Prendinger H. & Ishizuka M. (Eds.), *Life-like Characters. Tools, Affective Functions and Applications*. Springer-Verlag, Berlin, 65-86.

Doenges P., Capin T., Lavagetto F., Ostermann J., Pandzic I., Petajan E. (1997), MPEG-4: Audio/video and Synthetic Graphics/Audio for Real-Time, Interactive Media Delivery, *Signal Processing: Image Communication*, 9(4), 433-463.

Douglas_Cowie E., Campbell N. (Eds.) (2003), *Special Issue on Speech and Emotion*, in *Speech Comm.*, 40 (1-2), 1-258.

Drioli C., Tisato G., Cosi P., F. Tesser. (2003), Emotions and Voice Quality: Experiments with Sinusoidal Modeling, *Proc. of Voqual 2003, Voice Quality: Functions, Analysis and Synthesis, ISCA Workshop*, Geneva (Switzerland), 127-132.

Drioli C., Tisato G., Cosi P., F. Tesser. (2004), Control of Voice Quality for Emotional Speech Synthesis, *Proc. of AISV 2004*, Padova (Italy), (in press).

Ekman P., Friesen W. (1977), *Manual for the Facial Action Coding Systems*, Consulting Psychologist Press Inc., Palo Alto (USA).

Ekman P., Friesen W. (1978), *Facial Action Coding System*, Consulting Psychologist Press Inc., Palo Alto (USA).

Farnetani E., Recasens D. (1999), Coarticulation Models in Recent Speech Production Theories, in Hardcastle W.J. (Eds.), *Coarticulation in Speech Production*, Cambridge University Press, Cambridge, 31-68.

Ferrigno G., Pedotti A. (1985), ELITE - A digital dedicated hardware system for movement analysis via real-time TV signal processing. *IEEE Transactions on Biomedical Engineering*, vol. 32., 943-950.

Festival Home Page: <http://www.cstr.ed.ac.uk/projects/festival/>

Henke W.L. (1966), Dynamic articulatory model of speech production using computer simulation, Unpublished doctoral dissertation, MIT Cambridge, Ma, 1966.

Iida A., Campbell N., Higuchi F., Yasumara M. (2003), A Corpus-Based Speech Synthesis System with Emotion, *Speech Comm.*, Vol. 40, 161-187.

InterFace Home Page: <http://www.pd.istc.cnr.it/LUCIA/home/tools.htm>.

Keating P. (1990), The window model of coarticulation: articulatory evidence. In M.E. Beckam, (eds.), *Papers in Laboratory Phonetics I: between the grammar and the physics of speech*, 451-470. Cambridge University Press.

Keltner D., Ekman P., Gonzaga G., Beer J. (2003), Facial Expression of Emotions, in R. Davidson, H. Goldsmith, K. Scherer (Eds.) *Handbook of the Affective Sciences*, Oxford University Press, New York, 415-432.

Kozhevnikov V., Chistovich L. (1965), Speech: Articulation and Perception, *Joint Publications Research Service*, Washington, DC, Vol. 30, series 534.

Lavagetto F., Pockaj R. (1999), The Facial Animation Engine: Towards a High-Level Interface for the Design of Mpeg-4 Compliant Animated Faces, *IEEE Trans. on Circuits and Systems for Video Technology*, 9(2), 277-289.

Le Goff B., Guiard-Marigny T., Cohen M., Benoît C. (1994), Real-time Analysis-Synthesis and Intelligibility of Talking Faces, in *Proc. of the second ESCA/IEEE Workshop on Speech Synthesis*, New Paltz, New York, 53-56.

Le Goff B., Benoît C. (1996), A Text-To-Audiovisual-Speech Synthesizer for French, in *Proc. of ICSLP '96: The Fourth International Conference on Spoken Language Processing*, Philadelphia, 2163-2166

Le Goff B. (1997), *Synthèse A Partir du Texte de Visages 3D Parlant Français*, PhD Thesis, Grenoble, France.

Lee Y., Terzopoulos D., Waters K. (1995), Realistic Face Modeling for Animation, in *Proc. of SIGGRAPH '95*, 55-62.

Löfqvist A. (1990), Speech as Audible Gestures, in *Speech Production and Speech Modeling*, W. Hardcastle, A. Marchal (Eds.), Dordrecht: Kluwer Academic Publishers, 289-322.

Loquendo Home Page: <http://www.loquendo.it>

Magno Caldognetto E., Vaggés K., Ferrigno G., Zmarich C. (1993), Articulatory Dynamics of Lips in Italian /VpV/ and /VbV/ sequences *Proc. of Eurospeech '93*, Berlin, Vol. 1, 409-413.

Magno Caldognetto E., Zmarich C., Cosi P., Ferrero F. (1997), Italian Consonantal Visemes: Relationships Between Spatial/Temporal Articulatory Characteristics and Co-Produced Acoustic Signal, in C. Benoit and R. Campbell, (Eds.), *Proc. of AVSP'97*, Rhodes (Greece), 5-8.

Magno Caldognetto E., Zmarich C., Cosi P. (1998), Statistical Definition of Visual Information for Italian Vowels and Consonants, in D. Burnham, J. Robert-Ribes, E. Vatikiotis-Bateson, (Eds.), *Proc. of AVSP'98*, Terrigal-Sydney (Australia), 135-140.

Magno Caldognetto E., Poggi I. (2001), Dall'Analisi della Multimodalità Quotidiana alla Costruzione di Agenti Animati con Facce Parlanti ed Espressive, in Magno Caldognetto E.

and Cosi P. (Eds.) *Multimodalità e Multimedialità della Comunicazione, Atti delle XI Giornate di Studio del GFS*, Unipress, Padova, 47-55.

Magno Caldognetto E., Cosi P., Drioli C., Tisato G., Cavicchio F. (2003), Co-production of Speech and Emotion: Bi-Modal Audio-Visual Changes of Consonant and Vowel Labial Targets, *Proc. AVSP 2003, Audio Visual Speech Processing, ISCA Workshop*, St. Jorioz (France), 209-214.

Magno Caldognetto E., Cosi P., Drioli C., Tisato G., Cavicchio F. (2004), Modifications of Phonetic Labial Targets in Emotive Speech: Effects of the Co-Production of Speech and Emotions, *Speech Communication: Special issue on audio visual speech processing*, Vol. 44, 173-185.

Massaro D. (1987), Speech Perception by Ear and Eye: A Paradigm for Psychological Inquiry, in Dodd B. and Campbell R. (Eds.), *Hearing by Eye: The Psychology of Lip-Reading*, Lawrence Erlbaum Associates, Hillsdale, New Jersey, 53-83.

Massaro D. (1996), Bimodal Speech Perception: A Progress Report, in Stork D. and Hennecke M. (Eds.) *Speech-reading by Humans And Machine: Models, Systems and Applications*, Springer-Verlag, New York, 79-102.

Massaro D. (1998), *Perceiving Talking Faces: from Speech Perception to a Behavioral Principle*, A Bradford book, the MIT Press, Cambridge, Massachusetts.

Massaro, D., and Egan, P. (1998), Perceiving Affect from the Voice and the Face, *Psychological Bulletin*, 3, 1021-1032.

Massaro D., M. Cohen M., Beskow J., Cole R. (2000), Developing and Evaluating Conversational Agents, in Cassell J., Sullivan J., Prevost S., Churchill E. (Eds), *Embodied Conversational Agents*, MIT Press, Cambridge, MA, 287-318.

Mbrola Home Page: <http://www.tcts.fpms.ac.be/synthesis/mbrola>

McGurk H., MacDonald J. (1976), Hearing Lips and Seeing Voices, *Nature*, 264, 746-748.

MPEG-4 Standard Home Page: <http://mpeg.telecomitalia.com/standards/MPEG-4>

Munhall K.G., Löfqvist A. (1992), Gestural aggregation in speech: laryngeal gestures, *Journal of Phonetics*, 1992, Vol. 20, 111-126.

Öhman S. (1966), Coarticulation in VCV utterances: spectrographic measurements, *Journal of Acoustical Society of America*, 1966, Vol. 39, 151-168.

Öhman S. (1967), Numerical model of coarticulation, *Journal of Acoustical Society of America*, 1967, Vol. 41, 310-320.

Parke F. (1974) *A Parametrical Model for Human Face*, Ph.D Thesis, *Tech. Report UTEC-CSc-75-047*, University of Utah, Salt Lake City (USA).

Parke F. (1982), Parametrized Models for Facial Animation, *IEEE Computer Graphics*, 2(9), 61-68.

Pasquariello S. (2000), *Modello per l'Animazione Facciale in MPEG-4*, M.S. Thesis, University of Rome.

- Pearce, B. Wyvill, G. Wyvill, D. Hill (1986), Speech and Expression: A Computer Solution to Face Animation, *Graphic and Vision '86*, 136-140.
- Pelachaud C., Magno Caldognetto E., Zmarich C., Cosi P. (2001), Modeling an Italian Talking Head, *Proc. AVSP 2001*, Aalborg, Denmark, 72-77.
- Perin G. (2001), *Facce Parlanti: Sviluppo di un Modello Coarticulatorio Labiale per un Sistema di Sintesi Bimodale*, M.S. Thesis, Univ. of Padova.
- Petajan E. (1984), *Automatic Lip-Reading to Enhance Speech Recognition*, PhD Thesis, Univ. of Illinois at Urbana-Champaign.
- Prendinger H. & Ishizuka M. (Eds.) (2004), *Life-like Characters. Tools, Affective Functions and Applications*. Springer-Verlag, Berlin, 65-86.
- Rank E., Pirker H.(1998), Generating Emotional Speech with a Concatenative Synthesizer, in *Proc. 5th International Conference on Spoken Language Processing (ICSLP'98)*, Sydney, Australia.
- Ruttkay Z., Noot H., ten Hagen P. (2003), Emotion Disc and Emotion Squares: Tools to Explore the Facial Expression Space, *Computer Graphics Forum*, 22(1), 49-53.
- Salzman E.L., Munhall K.G. (1989), A dynamical approach to gestural patterning in speech production, *Ecological Psychology*, 1989, Vol. 1, number 4, 333-382.
- Scherer K. (2003), Vocal Communication of Emotion: A Review of Research Paradigm, *Speech Comm.*, 40, 227-256.
- Scherer K., Johnstone T., Klasmeyer G. (2003), Vocal Expression of Emotion. In R. J. Davidson, H. Goldsmith, K. R. Scherer (Eds.), *Handbook of the Affective Sciences*, 433-456. New York, Oxford University Press.
- Schultz G., Schnabel R., Byrd R. (1985), A family of trust-region-based algorithms for unconstrained optimization with strong global convergence properties, *SIAM Journal on Numerical Analysis*, 1985, Volume 22, 47-67.
- Silsbee P., Allen A.C. (1993), Medium-Vocabulary Audio-Visual Speech Recognition, *Proc. NATO ASI, New advances and trends in speech recognition and coding*, 13-16.
- Soderkvist I. and Wedin P. (1993), Determining the movements of the skeleton using well-configured markers, *Journal of Biomechanics*, 26:1473-1477
- Stork D., Henneke M. (Eds.) (1996), *Speech-Reading by Humans and Machine: Models, Systems and Applications*, Springer-Verlag, New York.
- Stork D., Wolff G., Levine E. (1992), Neural Network Lip-Reading System for Improved Speech Recognition, *Proc. of IEEE International Joint Conference on Neural Networks, IEEE-IJCNN-92*, 285-295
- Summerfield Q. (1987), Some Preliminaries to a Comprehensive Account of Audio-Visual Speech Perception, in Dodd B. and Campbell R. (Eds.), *Hearing by Eye: The Psychology of Lip-Reading*, Lawrence Erlbaum Associates, Hillsdale, New Jersey, 3-51.
- Tesser F., Cosi P., Drioli C., Tisato G., (2004), Prosodic Data-Driven Modelling of a Narrative Style in FESTIVAL TTS, in *Proc. of the 5th ISCA Speech Synthesis Workshop*, Pittsburgh (USA), 185-190.

Tesser F., Cosi P., Drioli C., Tisato G., (2004), Modelli Prosodici Emotivi per la Sintesi dell'italiano, *Proc. of AISV 2004*, Padova (Italy), (in press).

Tiede, M., Vatikiotis-Bateson, E., Hoole, P., Yehia, H. (1999), *Magnetometer Data Acquisition and Analysis Software for Speech Production Research*, ATR Technical Report TRH 1999, ATR Human Information Processing Labs (Japan).

Vatikiotis-Bateson E., Munhall K., Hirayama M., Kasahara Y., Yehia H. (1996), Physiology-Based Synthesis of Audiovisual Speech, in *Proc. of 4th Speech Production Seminar: Models and Data*, 241-244.

Walden B., Prosek R., Montgomery A., Scherr C., Jones C. (1977), Effects of Training on the Visual Recognition of Consonants, *Journal of Speech and Hearing Research*, Vol. 20, 130-145.

Wolf R. (1983), *Elements of Photogrammetry*, Mc Graw-Hill Publisher.